



UNIVERSIDAD DE CUENCA

Facultad de Ingeniería

Maestría en Investigación en Ciencias de la Ingeniería para la Gestión de los Recursos Hídricos

Integración de un sistema de alerta temprana mediante modelación hidrodinámica y predicción de flujos con redes neuronales. Caso de estudio: río Tomebamba

Trabajo de titulación previo a la obtención del título de Magister en Investigación en Ciencias de la Ingeniería para la Gestión de los Recursos Hídricos

Autor:

Ing. Andrés Xavier Maza Mogrovejo

CI: 0104827282

Director:

Ing. Felipe Eduardo Cisneros Espinoza, PhD.

CI: 0101045540

Cuenca, Ecuador

31-octubre-2018



Resumen:

La zona urbana de la ciudad de Cuenca se ha visto afectada por las crecidas de sus ríos, provocando inundaciones en áreas residenciales; y, con ello pérdidas materiales o de vidas humanas. De modo que, conocer con anticipación el caudal que producirá daños es importante. Por esa razón, el objetivo del estudio es integrar un sistema de alerta temprana para pronosticar caudales diarios y evaluar la vulnerabilidad a inundaciones del río Tomebamba. En primer lugar, se construyó una red neuronal perceptrón multicapa de retro-propagación con Matlab para pronosticar caudales hasta tres días empleando datos de lluvia y caudal. A partir de una evaluación cualitativa (comparación gráfica) y cuantitativa (MSE, NS, R y PBIAS) se obtuvo un modelo capaz de predecir caudales de hasta un día; a pesar de ello, se presentaron sobreestimaciones de caudales bajos y subestimaciones de caudales altos en todas las modelaciones. En segundo lugar, se realizó una modelación fluvial con HEC-RAS para calibración y con Iber para modelar seis hidrogramas de crecida, lo que dio como resultado la ubicación de puntos de desbordamiento, áreas máximas, alertas y mapas de inundación de la zona. Así pues, los dos modelos en conjunto constituyen un sistema integral para pronóstico de crecidas en el río Tomebamba; en el que, el caudal pronosticado es comparado con umbrales fijados para tener una aproximación de los daños que podría ocasionar. Y con ello, establecer las acciones necesarias para su difusión y alerta por parte del organismo que maneje el sistema.

Palabras claves: Hidrología. Modelación hidrodinámica. Predicción de caudales. Perceptrón multicapa. Redes neuronales artificiales. Retro-propagación. Sistema de alerta temprana. Curvas Huff.



Abstract:

The urban area of the city of Cuenca has been affected by the flooding of its rivers causing flooding in residential areas and with it, material losses or human lives. Therefore, knowing in advance the flow that will cause damage is important. For that reason, the objective of the study is to integrate an early warning system to forecast daily flows and assess the vulnerability to floods of the Tomebamba River. First, a multilayer perceptron back-propagation neural network was constructed with Matlab to forecast flows up to three days using rainfall and flow data. From a qualitative (graphical comparison) and quantitative (MSE, NS, R and PBIAS) evaluation, a model capable of predicting flows up to one day was obtained. Nonetheless, there were overestimations of low flows and underestimations of high flows in all models. Secondly, a river modeling was performed with HEC-RAS for calibration and with Iber to model six flood hydrographs, which resulted in the location of overflow points, maximum areas, alerts and flood maps of the area. Hence, the two models together constitute an integral system for flood forecasting on the Tomebamba River. Wherein, the predicted flow is compared with established thresholds to have an approximation of the damages that could cause. By this means, establish the necessary actions for its dissemination and alert by the body that manages the system.

Keywords: **Hydrology.** Hydrodynamic modeling. Flow forecasting. Multilayer perceptron. Artificial neural networks. Back-propagation. Early warning system. Huff curves.



Índice del Trabajo

1. Capítulo I. Introducción.....	11
1.1 Antecedentes y Justificación	11
1.2 Objetivos	14
1.2.1 Objetivo General	14
1.2.2 Objetivos Específico.....	14
2. Capítulo II. Marco Teórico	15
2.1 Redes Neuronales Artificiales (ANN)	15
2.1.1 Definición	15
2.1.2 Arquitectura de una red neuronal	16
2.1.3 Algoritmo de aprendizaje: Back-propagation	18
2.1.4 Pre/post-procesamiento de datos.....	20
2.1.5 Evaluación del modelo	20
3. Capítulo III. Materiales y Métodos	23
3.1 Área de Estudio	23
3.1.1 Geología, Cobertura y Uso del suelo y de la microcuenca	24
3.1.2 Características físicas de la microcuenca	25
3.1.3 Hidrología de la microcuenca	26
3.1.4 Estaciones de monitoreo	27
3.2 Modelo de predicción de caudales	28
3.2.1 Información disponible	28
3.2.2 Implementación del modelo	29
3.2.3 Escenarios de modelación	30
3.3 Modelación hidrodinámica del río Tomebamba	31
3.3.1 Información disponible	31
3.3.2 Modelación hidrológica	31
3.3.3 Implementación del modelo fluvial	33
3.3.4 Evaluación del modelo fluvial	33
4. Capítulo IV. Resultados y Discusión	35
4.1 Análisis hidrológico de las series temporales.....	35
4.2 Modelo predictivo de caudales	39
4.2.1 Preparación de la información.....	39
4.2.2 Análisis preliminar y selección de parámetros de la red	39
4.2.3 Escenarios de modelación	44
4.3 Modelo hidrodinámico	53
4.3.1 Modelación hidrológica	53
4.3.2 Modelación hidráulica	58
4.4 Integración del SAT	73
5. Capítulo V. Conclusiones y Recomendaciones	75
5.1 Conclusiones	75
5.2 Recomendaciones y futuros trabajos	78
6. Referencias	79



Índice de Tablas

Tabla 2.1 Funciones de transferencia.....	16
Tabla 2.2 Rendimiento del modelo en función del NS	21
Tabla 3.1 Parámetros físicos de la microcuenca	26
Tabla 3.2 Listado de estaciones de monitoreo presentes en la microcuenca	27
Tabla 3.3 Cantidad de tormentas clasificadas por cuartiles y estación	32
Tabla 4.1 Resultados óptimos de los tres modelos del escenario 1	45
Tabla 4.2 Resultados óptimos de los tres modelos del escenario 2.....	49
Tabla 4.3 Tipo de suelo y grupo hidrológico existentes en la cuenca de Balzay	55
Tabla 4.4 Números de curva para cada grupo hidrológico en función de las coberturas presentes en la cuenca de Balzay	55
Tabla 4.5 Ecuaciones IDF para las estaciones CH y MS	56
Tabla 4.6 Caudales máximos obtenidos de los hidrogramas de diseño para diferentes períodos de retorno.....	58
Tabla 4.7 Calados y velocidades máximas en la modelación de hidrogramas de crecida	62
Tabla 4.8 Áreas de inundación sobre la zona residencial	70
Tabla 4.9 Zonas y caudales asociados a desbordamientos del río Tomebamba	71
Tabla 4.10 Umbrales de alerta para inundaciones en el río Tomebamba	73
Tabla 4.11 Niveles y acciones de alerta para el SAT	74



Índice de Figuras

Figura 2.1. Esquema del modelo conceptual de una red neuronal artificial	15
Figura 2.2. Perceptrón Multicapa	17
Figura 2.3. Curvas de descarga de las estaciones aforadas.....	18
Figura 3.1. Tramo del río Tomebamba que será empleado para la modelación hidrodinámica	23
Figura 3.2. Microcuenca del río Matadero tomando como punto de cierre el sector de Sayausí.....	24
Figura 3.3. Cobertura y uso de suelo de la microcuenca de Matadero	25
Figura 3.4. Ubicación de las estaciones de monitoreo existentes en la microcuenca de Matadero ...	28
Figura 3.5. Porcentaje de información disponible por años de cada estación	29
Figura 3.6. Curvas de descarga de las estaciones aforadas.....	34
Figura 4.1 Serie temporal, diagrama de caja e histograma de precipitaciones de la estación MS a escala diaria, mensual y anual	35
Figura 4.2 Serie temporal, diagrama de caja e histograma de caudales de la estación MS a escala diaria, mensual y anual.....	36
Figura 4.3 Serie temporal, diagrama de caja e histograma de precipitaciones de la estación CH a escala diaria, mensual y anual	36
Figura 4.4 Heatmap de precipitación mensual para los registros históricos de la estación MS.....	37
Figura 4.5 Heatmap de precipitación mensual para los registros históricos de la estación CH	38
Figura 4.6 Precipitación media mensual de las estaciones MS y CH.....	38
Figura 4.7 Diagramas de autocorrelación de la estación MS	40
Figura 4.8 Diagrama de autocorrelación de la estación CH	40
Figura 4.9 Comparación de datos observados y modelados (primera aproximación)	42
Figura 4.10 Arquitectura de red neuronal (NNTools)	42
Figura 4.11 Análisis de sensibilidad de la tasa de aprendizaje y momentum.....	43
Figura 4.12 Análisis de sensibilidad de las neuronas en la capa oculta	44
Figura 4.13 Etapa de calibración – A1	46
Figura 4.14 Etapa de calibración – A2.....	46
Figura 4.15 Etapa de calibración – A3.....	47
Figura 4.16 Etapa de validación – A1	47
Figura 4.17 Etapa de validación – A2.....	48
Figura 4.18 Etapa de validación – A3.....	48
Figura 4.19 Etapa de calibración – B1	50
Figura 4.20 Etapa de calibración – B2.....	50
Figura 4.21 Etapa de calibración – B3.....	51
Figura 4.22 Etapa de validación – B1	51
Figura 4.23 Etapa de validación – B2.....	52
Figura 4.24 Etapa de validación – B3.....	52
Figura 4.25 Cobertura y uso del suelo de la cuenca con cierre en Balzay	54
Figura 4.26 Curvas de Huff para las estaciones CH y MS	56
Figura 4.27 Hietogramas de diseño de la cuenca de Balzay	57
Figura 4.28 Hidrogramas de diseño para diferentes periodos de retorno	57
Figura 4.29 Ortofoto del río Tomebamba y zonificación de suelos para el coeficiente de rugosidad..	59
Figura 4.30 Comparación de curvas de descarga simuladas con datos aforados.....	60
Figura 4.31 Perfil de terreno, de flujo y crítico para un caudal de 43.65 m ³ /s (tramo puente Balzay y Feria Libre)	61



Figura 4.32 Nivel de agua para el caudal de 43.65 m ³ /s en el tramo final de modelación.....	61
Figura 4.33 Mapa de calados máximos para un periodo de retorno de 2 años	63
Figura 4.34 Mapa de calados máximos para un periodo de retorno de 5 años	64
Figura 4.35 Mapa de calados máximos para un periodo de retorno de 10 años	65
Figura 4.36 Mapa de calados máximos para un periodo de retorno de 25 años	66
Figura 4.37 Mapa de calados máximos para un periodo de retorno de 50 años	67
Figura 4.38 Mapa de calados máximos para un periodo de retorno de 100 años	68
Figura 4.39 Máximas áreas de inundación para cada periodo de retorno (Tramo Puente Feria Libre – Puente Av. Unidad Nacional).....	69
Figura 4.40 Zona de velocidades máximas para un periodo de retorno de 100 años	70



Cláusula de licencia y autorización para publicación en el Repositorio Institucional

Andrés Xavier Maza Mogrovejo en calidad de autor/a y titular de los derechos morales y patrimoniales del trabajo de titulación "Integración de un sistema de alerta temprana mediante modelación hidrodinámica y predicción de flujos con redes neuronales. Caso de estudio: río Tomebamba", de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 31 de octubre de 2019

Andrés Xavier Maza Mogrovejo

C.I: 0104827282



Cláusula de Propiedad Intelectual

Andrés Xavier Maza Mogrovejo, autor/a del trabajo de titulación "Integración de un sistema de alerta temprana mediante modelación hidrodinámica y predicción de flujos con redes neuronales. Caso de estudio: río Tomebamba", certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor/a.

Cuenca, 31 de octubre de 2019

Andrés Xavier Maza Mogrovejo

C.I: 0104827282



Dedicatoria

Este trabajo lo dedico a mi familia por haber sido mi apoyo durante la maestría y a lo largo de mi vida y a todas las personas especiales que me acompañaron en esta etapa, aportando a mi formación tanto profesional y como personal.

Agradecimientos

A todos mis amigos, que me ayudaron de una manera desinteresada, gracias infinitas por toda su ayuda y buena voluntad.

Al Programa para el Manejo del Agua y Suelo, por haberme brindado sus instalaciones y equipamiento para el desarrollo del trabajo.

Al programa de maestría, pues gracias a su apoyo económico pude participar en la Conferencia Conjunta de Bosques y Agua en la ciudad de Valdivia, Chile con un artículo procedente del presente trabajo.

Por último, a los docentes que fueron parte de este trabajo, con su sabiduría y conocimiento me apoyaron a culminar la investigación.



1. Capítulo I.

Introducción

1.1 Antecedentes y Justificación

Las inundaciones son procesos naturales en el que se da una ocupación de agua en zonas que normalmente no existe circulación de agua, son producto de diversos procesos hidrológicos, aunque pueden resultar como consecuencia por acciones antrópicas (cambios de cursos de ríos); y, su magnitud dependerá de las condiciones climáticas principalmente. Por lo general, están asociados a eventos de lluvias de gran intensidad que incrementan la escorrentía superficial y a la vez los caudales que fluyen por los ríos, dado que no toda la lluvia se infiltra; así pues, aumenta la cantidad de sedimentos transportados por los cauces afectando zonas susceptibles de erosión. Por esta razón, se producen inundaciones principalmente en zonas planas, además tomando en cuenta que los cursos de agua acarrean palizadas y sedimentos (rocas y suelos) en las crecidas, podrían taponar los cauces de los ríos parcial o totalmente y así ocurrir inundaciones en zonas altas, ya que no se cuenta con la capacidad suficiente para evacuar el exceso de escurrimiento. Este fenómeno ha afectado históricamente a poblaciones alrededor del mundo y es por ello, que el hombre ha construido obras civiles hidráulicas y estructurales, a fin de controlar y amortiguar de cierto grado las inundaciones.

La ciudad de Cuenca, ubicada al sur del Ecuador, tiene aproximadamente 350 000 habitantes por lo que es considerada como la tercera ciudad principal del país, se caracteriza por ofrecer un diverso paisaje debido a su ubicación geográfica y condiciones climáticas; además, se la conoce como Santa Ana de los Cuatro Ríos porque es atravesada por cuatro ríos, siendo éstos el Tarquí, Yanuncay, Tomebamba y Machángara; los cuales constituyen un importante recurso hídrico para la ciudad. Un recorrido a lo largo de éstos ríos, ha puesto en evidencia la presencia de ciertas construcciones civiles en las cercanías de sus orillas, como es el caso de las oficinas y bodegas de la Empresa Pública Municipal de Telecomunicaciones, Agua Potable, Alcantarillado y Saneamiento (ETAPA-EP) y la Escuela de Bomberos de la ciudad, en el curso del río Yanuncay. Las ordenanzas vigentes del cantón Cuenca, en el Art. 15, del capítulo tres, en cuanto a usos de suelo en la ciudad establece una longitud mínima de 50 m medidos a partir de la orilla de los ríos, en la que no se puede urbanizar (Cuenca, 2002); en vista de que las edificaciones de las entidades municipales antes mencionadas no cumplen con esta norma, en eventos de crecida sufren afecciones (inundaciones) por el incremento del nivel del río.

De acuerdo a lo reportado por Vallejo Llerena (2014), la ciudad se ha visto afectada en los últimos años por la ocurrencia de grandes lluvias principalmente en la época invernal y que en ocasiones han producido taponamientos de los colectores y alcantarillas, produciendo inundaciones en las orillas de los ríos y quebradas en ciertos sectores de la ciudad. El último evento de crecida, difundido por ETAPA-EP el día 5 de junio de 2019¹, tuvo alerta de desbordamiento para los ríos Tomebamba y

¹ Para detalles referirse al enlace: <https://www.elcomercio.com/actualidad/alerta-desbordamiento-rios-cuenca-lluvias.html>



Yanuncay, aunque no existió un registro de daños o desbordamientos, se conoce que ciertos sectores como el coliseo Jefferson Pérez², Puertas del Sol y Balzay³ son vulnerables a inundaciones por crecidas de los ríos. Todo esto ha conducido a pérdidas de bienes materiales que se encuentra muy cercanos a los cauces y también pérdidas de vidas humanas, a pesar de que las instituciones de control realizan operativos de vigilancia de los ríos; cabe mencionar que esta última ocurre porque ocasionalmente se realizan actividades humanas como lavado de ropa, pesca, entre otras. Los eventos de crecida ocurren en tiempos cortos y además existe cierta incertidumbre en cuanto a su magnitud y al establecimiento de zonas que podrían ser afectadas, resulta complejo tomar medidas adecuadas para mitigar las afecciones producidas. En este contexto, es necesario contar con un sistema de monitoreo y pronóstico de caudales en los ríos, que permita identificar la magnitud y ubicación de zonas vulnerables de inundación, a fin de evitar futuras pérdidas en la ciudad. Por tal motivo, este sistema resulta sumamente importante para una gestión apropiada de los recursos hídricos, en especial en zonas que son altamente vulnerables a inundaciones.

En la actualidad el Ecuador dispone de una red de estaciones hidrológicas y meteorológicas que permiten el monitoreo continuo de las cuencas hidrográficas. La principal red de estaciones está a cargo del Instituto Nacional de Meteorología e Hidrología (INAMHI) y es el encargado de realizar el control hidrometeorológico del país; está vinculado a la Secretaría de Gestión de Riesgos y es miembro de la Organización Meteorológica Mundial (OMM). A la par, existen otras instituciones que realizan el monitoreo de ríos y cuencas hidrográficas alrededor del país; para el caso de la ciudad de Cuenca, se puede mencionar a la Empresa Pública Municipal de Telecomunicaciones, Agua Potable, Alcantarillado y Saneamiento (ETAPA-EP) y al Programa para el Manejo del Agua y Suelo (PROMAS), organismo que pertenece a la Universidad de Cuenca; las cuales disponen de su propia red de monitoreo.

Un sistema de predicción de caudales tiene por objetivo establecer un caudal de ocurrencia en el futuro tomando en cuenta fenómenos hidrológicos de la cuenca, es decir constituye un modelo hidrológico para representar la relación lluvia-escorrentía. Existen diversos modelos hidrológicos que permiten realizar la predicción de flujos, sin embargo, la selección del modelo más apropiado debe cumplir con ciertos objetivos, dependiendo de los requerimientos de las partes interesadas y los usuarios finales de las predicciones (World Meteorological Organization, 2011). Los modelos hidrológicos convencionales utilizados para modelar los procesos de lluvia-escorrentía, son los modelos físicos y conceptuales. Los primeros se basan en procesos físicos y se fundamentan en el balance de masa y energía y por tanto tienen significado físico; mientras que los modelos conceptuales se basan principalmente en la conservación de la masa asociado con una representación simplificada de las ecuaciones de momentum y energía (Yilmaz et al., 2011). Una alternativa a estos enfoques son las Redes Neuronales Artificiales (*ANN por sus siglas en inglés*); se consideran como modelos de caja negra o “black box”, porque no están gobernados por los procesos

² Para detalles referirse al enlace: <https://www.eluniverso.com/2012/06/25/1/1447/sectores-cuenca-inundados-desbordamiento-río-tomebamba.html>

³ Para detalles referirse al enlace: <https://www.eluniverso.com/noticias/2014/10/11/nota/4093946/crecida-río-tomebamba-pone-alerta-cuenca>



físicos que describen un fenómeno, si no que se basan en las relaciones existentes entre las variables consideradas. Minns y Hall (1996) establecen que las ANN trabajan con lluvias y caudales totales y, por tanto, no hay necesidad de aplicar funciones de pérdida y técnicas de separación de flujo base como los modelos convencionales. Asimismo, otra de las razones en el uso de modelos ANN sobre modelos estadísticos tradicionales, es que éstos últimos usualmente son muy restrictivos, lo que hace difícil emplearlos para aplicaciones de la vida real (Maier and Dandy, 2000). Existen diversos tipos y configuraciones de redes neuronales, no obstante Campolo et al. (2003) indican que las redes hacia adelante (feedforward) son ampliamente usadas en aplicaciones hidrológicas porque son simples, precisas y presentan altas velocidades de procesamiento; además, este tipo de redes está asociado a una estructura denominada perceptrón multicapa (*MLP por sus siglas en inglés*), que consiste en tres capas conectadas en serie, básicamente.

En base a una amplia revisión bibliográfica de lo anterior, se ha identificado que existe una falta de aplicaciones de modelos ANN con la estructura antes mencionada para Latinoamérica, de hecho, la mayor cantidad de investigaciones se han concentrado en Turquía y USA; dando muy buenos resultados en la predicción de variables hidrológicas como temperatura, precipitación, niveles de agua y caudales. El trabajo realizado por Veintimilla et al. (2016), resulta ser uno de los escasos estudios de Latinoamérica, y más concretamente para la ciudad de Cuenca, Ecuador. En el estudio se presentan resultados prometedores en la predicción de caudales a nivel diario para la cuenca del río Tomebamba, mediante un modelo ANN en conjunto con el algoritmo retro-propagación (back-propagation), para un período de cinco meses; cabe mencionar que, los pronósticos se realizan en el sector de Ucubamba, punto en el que existe la confluencia con los ríos Tarqui y Yanuncay. De esta manera, se ha evidenciado que este tipo de modelos funcionan adecuadamente para las condiciones locales que presenta la cuenca del río Tomebamba.

A partir de los resultados antes mencionados, se cree que una red neuronal bien estructurada permitirá pronosticar caudales con el suficiente tiempo de antelación, como para que constituya una herramienta de primera mano para la gestión de inundaciones en la ciudad de Cuenca; y, por tanto, la presente investigación tiene por objetivo construir un modelo predicción de caudales a nivel diario, de la microcuenca del río Matadero (afluente del río Tomebamba), empleando redes neuronales artificiales de perceptrón multicapa con algoritmo de entrenamiento back-propagation. La selección de este algoritmo obedece al hecho de que según Coulibaly et al. (2000) el 90% de modelos ANN aplicados en la hidrología lo utilizan. Con ello se pretende realizar predicciones de caudales en tiempo real, es decir, considerando toda la serie temporal y no solo un evento o período determinado. Al mismo tiempo, la investigación está orientada a la integración de un Sistema de Alerta Temprana (SAT), para ello, y partiendo del modelo hidrológico de predicciones es necesario evaluar cuáles serían los posibles daños ocasionados por la ocurrencia del caudal pronosticado; por consiguiente, se ha considerado necesario determinar cómo escurre dicho caudal en el río aguas abajo. Por esta razón, la modelación hidrodinámica del río Tomebamba aguas abajo del punto de predicción, permitirá establecer zonas susceptibles de inundación.



Así pues, la implementación de un SAT resulta ser una significativa solución no estructural, basada en un monitoreo hidrometeorológico y modelación hidrodinámica del río Tomebamba, que permita predecir caudales con suficiente antelación y precisión para tomar acciones necesarias a fin de evitar pérdidas y daños a la ciudad. Este modelo de predicción integrado estará a disposición de aquellas instituciones que realizan estudios y monitoreo en la cuenca, tales como el PROMAS, Universidades, ETAPA-EP y de organismos de seguridad como el ECU911. Por otro lado, el sistema podría ser replicado en otros sitios de interés en el país, de modo que el INAMHI y el Servicio Nacional de Gestión de Riesgos y Emergencias serían los principales actores en el desarrollo futuro de este tipo de proyectos a nivel nacional.

1.2 Objetivos

1.2.1 Objetivo General

Integrar un Sistema de Alerta Temprana (SAT) para la ciudad de Cuenca, que permita predecir caudales a nivel diario, mediante un modelo ANN y modelación hidrodinámica del río Tomebamba.

1.2.2 Objetivos Específico

- Construir, calibrar y validar un modelo de predicción de caudales mediante Redes Neuronales Artificiales (ANN).
- Construir, calibrar y validar un modelo hidrodinámico de un tramo del río Tomebamba, dentro de la zona urbana de la ciudad de Cuenca.
- Identificar zonas vulnerables a inundaciones.
- Constituir el Sistema de Alerta Temprana (SAT).

2. Capítulo II.

Marco Teórico

2.1 Redes Neuronales Artificiales (ANN)

2.1.1 Definición

Las redes neuronales artificiales son modelos matemáticos, considerados como modelos de caja negra (Campolo et al., 1999), capaces de representar comportamientos no lineales; inspirados en el sistema nervioso humano basado en las teorías de la interconexión masiva y la arquitectura de procesamiento paralelo de los sistemas neuronales biológicos (Aichouri et al., 2015); con el objeto de solucionar complejos problemas matemáticos de manera sencilla.

El modelo matemático conceptual de una red neuronal está conformado por una red de neuronas interconectadas entre sí, las cuales son las encargadas de procesar la información y resolver el problema a través de un algoritmo de aprendizaje; y así establecer relaciones entre las variables consideradas. Cada una de las neuronas tiene asociado un valor denominado “peso” que permite mejorar la capacidad de aprendizaje de la red (rendimiento), a través de un algoritmo matemático, el cuál modifica y ajusta el valor del peso en base a una función de error. En la Figura 2.1 se presenta un esquema del modelo de una ANN.




Figura 2.1. Esquema del modelo conceptual de una red neuronal artificial

Fuente: (Araghinejad, 2013).

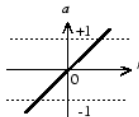
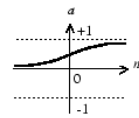
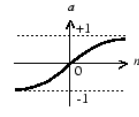
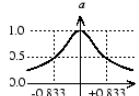
Cada una de las neuronas tienen parámetros de entrada (x_1, x_2, \dots, x_m), los cuales son procesados dentro de la neurona y producen una salida (Y). Este valor se determina mediante una suma ponderada de los pesos de cada conexión. Adicionalmente, las neuronas tienen un parámetro adicional denominado bias. La expresión matemática que detalla dicho proceso se la conoce como perceptrón, y está dada por la expresión (Araghinejad, 2013):

$$I = \sum_{j=1}^m w_j x_j + b \quad (2.1)$$

$$Y = \begin{cases} 1 \rightarrow \text{si } I \geq \theta \\ 0 \rightarrow \text{si } I < \theta \end{cases} \quad (2.2)$$

En dónde, x_j son las entradas; w_j son los pesos de las conexiones; b es el bias; I es la suma de todas las entradas por los pesos asociados; θ es el nivel de umbral; y , Y es la salida.

La salida de una neurona se determina con la suma ponderada de los pesos mediante una función de transferencia o activación. Existen diversos tipos de funciones que se pueden aplicar (ver Tabla 2.1); sin embargo, Maier y Dandy (2000) y Dawson y Wilby (2001) indican que la función logaritmo sigmoide o sigmoide y la función tangente hiperbólica sigmoide se emplean frecuentemente.

Tabla 2.1 Funciones de transferencia		
Nombre	Función	Gráfica
Lineal	$f(x) = x$	
Sigmoide	$f(x) = \frac{1}{1 + e^{-\alpha x}} \quad \alpha > 0$	
Tangente sigmoide	$f(x) = \left(\frac{2}{1 + e^{-\alpha x}} \right) - 1 \quad \alpha > 0$	
Base radial	$f(x) = e^{-x^2/\sigma^2}$	

Elaboración: Xavier Maza, 2019. **Fuente:** Adaptado de (Beale et al., 1992; Araghinejad, 2013).

2.1.2 Arquitectura de una red neuronal

La arquitectura o configuración de la red que ha sido empleada en el presente estudio se denomina perceptrón multicapa (*MLP por sus siglas en inglés*). Dicha estructura está constituida por tres capas, que se conocen como capa de entrada, oculta y salida. En el que, cada una de ellas puede contener varias neuronas o nodos; además, la capa oculta puede contener dos capas, cada una con distinto número de neuronas. Las neuronas que conforman la capa de entrada están definidas por las variables de entrada al modelo; las neuronas que forman la capa oculta son las que determinan la capacidad de aprendizaje del modelo; y, las neuronas que se encuentran en la capa de salida se

refieren a la cantidad de variables que el modelo dará como resultado, por lo que puede ser más de una. Cabe señalar que si el número de nodos en la capa oculta es pequeño, la red podría no ser capaz de aprender correctamente; y, si es muy alto la red podría causar sobreajustes de los datos (Kışı, 2004). En la Figura 2.2 se indica una representación de la arquitectura MLP.





Figura 2.2. Perceptrón Multicapa

Elaboración: Xavier Maza, 2019.

En vista de la capacidad de una ANN para dar como resultado más de una salida, se puede realizar predicciones en un horizonte de tiempo, tomando en cuenta el paso de tiempo de los datos de entrada; con lo cual, se pueden realizar predicciones por minutos, horas, días, semanas, meses y años. En este sentido, escalas horarias y diarias pueden considerarse como predicciones a corto plazo; mientras que tiempos mayores, se consideran como predicciones a largo plazo (Yaseen et al., 2016). Se recomiendan predicciones a corto plazo para alertas y protecciones por inundaciones; y, a largo plazo para operaciones de reservorios y gestión de riego como la asignación de agua, programación de descargas y mitigación de sequías (Zealand et al., 1999; Toth et al., 2000; Li et al., 2013; Yaseen et al., 2016).

Las predicciones para horizontes de tiempo pueden desarrollarse de dos maneras. La primera se conoce como el método recursivo de paso múltiple; aquí la red tiene una salida y este valor se utiliza en la siguiente iteración como parámetro de entrada para el siguiente pronóstico. El segundo se denomina método directo de paso múltiple, en este caso la red neuronal está compuesta por varias salidas, en el que cada una representa un paso de tiempo a predecir; es decir, que las salidas no se convierten en entradas para el siguiente pronóstico. El esquema de estos métodos se indica en la Figura 2.3.

Para el desarrollo de la presente investigación se ha empleado el método directo, ya que, Toth et al. (2000) y Varoonchotikul (2003) señalan que en el pronóstico de horizontes de tiempo con el método recursivo, el error se acumula y se propaga desde la primera predicción hacia los siguientes valores; provocando que el modelo no sea el más adecuado.



Dónde: P es la precipitación en el tiempo t , w son los pesos de las conexiones, b son los bias de las neuronas, (a) Método recursivo, (b) Método directo

Figura 2.3. Curvas de descarga de las estaciones aforadas

Fuente: (Toth et al., 2000).

2.1.3 Algoritmo de aprendizaje: Back-propagation

El algoritmo back-propagation es un tipo de aprendizaje supervisado, es decir, que además de conocer los parámetros o variables de entrada se conoce el valor de salida; por consiguiente, se conoce el error producido entre el valor de salida conocido (observado) y el valor calculado (simulado). El algoritmo se basa en el método de la pendiente pronunciada (Maier and Dandy, 2000) y se lo conoce como la regla delta generalizada dado que modifica las expresiones matemáticas para utilizarlas de manera iterativa y determinar el gradiente (Araghinejad, 2013).

El algoritmo funciona una vez que se ingresa un conjunto de datos en la capa de entrada al igual que las respuestas deseadas. Mediante la suma ponderada y considerando los pesos de cada conexión, se establece la salida de la red pasando por cada una de las capas. En la capa de salida se calcula el error producido entre los valores observados y simulados; dichos errores son distribuidos a cada neurona hacia atrás, entre la capa de salida y la oculta, entonces se ajustan los pesos de cada conexión. La actualización de los pesos para cada par entrada-salida en un paso de tiempo dado a través del conjunto de datos se denomina iteración o epoch. Por lo tanto, y de manera iterativa la red mejora su aprendizaje hasta que los pesos se estabilizan y el rendimiento del modelo sea aceptable. Esto se realiza en base a una función de error, que usualmente corresponde al error medio cuadrático; y, permite detener el proceso iterativo, una vez que el error alcanza su máximo.

El algoritmo back-propagation trabaja sobre los pesos de las conexiones y los cambia de manera iterativa hasta que el error total es mínimo (Dawson and Wilby, 2001). La actualización de los pesos se realiza a través de la distribución del error cuadrático de ajuste del modelo, según la importancia

de cada peso respecto a su contribución al error total (Braham B and Varas C, 2003); la expresión que define el cambio en los pesos está dada por (Jimbo Pinos and Reinoso Vázquez, 2008):

$$w_{ji}(t+1) = w_{ji}(t) + [\alpha \cdot \delta_{pj} \cdot y_{pj} + \beta \cdot \Delta w_{ji}(t)] \quad (2.3)$$

Al mismo tiempo, existen dos casos para la expresión anterior:

- a) Cuando j es una neurona de salida, es decir la variación de los pesos van hacia una capa externa:

$$\delta_{pj} = (d_{pj} - y_{pj}) \cdot f_j'(h_j) \quad (2.4)$$

- b) Cuando j es una neurona oculta, es decir la variación de los pesos va desde una capa hacia otra que no sea externa:

$$\delta_{pj} = \left(\sum_k \delta_{pk} \cdot w_{kj} \right) \cdot f_j'(h_j) \quad (2.5)$$

En dónde, $w(t+1)$, $w(t)$ son los pesos de las conexiones en el tiempo $t+1$ y t , respectivamente; α se conoce como tasa de aprendizaje; β es el momentum; y_p es la salida deseada (observado); d_p es la salida real (simulado); h_j es la función de entrada y está dado por la sumatoria de todos los valores de entrada, multiplicados por sus pesos respectivos (ecuación (2.1)); f_j' corresponde a la derivada de la función de activación y evaluada con el valor de h_j .

En cuanto a los valores de los parámetros que intervienen en la red se tiene que los bias siempre toman el valor de uno (Zealand et al., 1999), mientras que los pesos son definidos aleatoriamente; además, dejan de variar una vez que se completa el entrenamiento de la red, con lo cual se valida el rendimiento del modelo empleando el conjunto de datos de prueba (Altunkaynak, 2007). La tasa de aprendizaje afecta el tamaño del paso en la superficie de los pesos para cada iteración de entrenamiento, si se adopta un valor alto el proceso de convergencia será más rápido, pero se presentarán oscilaciones en torno a pesos no óptimos; y si es bajo se incrementará el número de iteraciones con el riesgo de caer en un mínimo local, resultando en una solución no óptima. Por otra parte, el momentum permite efectuar un proceso más uniforme y rápido del cambio de los pesos de las conexiones, ayuda a evitar caer en mínimos locales, reduce el efecto de las oscilaciones y acelera la convergencia al error mínimo (Zhang et al., 1998; Maier & Dandy, 2000; Dawson & Wilby, 2001; Abraham, 2005). Cabe mencionar que los dos parámetros únicamente pueden adoptar valores entre 0 – 1, y son seleccionados a través de la experimentación matemática mediante prueba y error.

2.1.4 Pre/post-procesamiento de datos

Los modelos de redes neuronales, como cualquier modelo matemático, requiere de un análisis estadístico preliminar de la base de datos considerada; y, al mismo tiempo debido a su configuración, es altamente dependiente de los datos puesto que afecta su rendimiento (Dawson and Wilby, 2001). En este sentido, es de suma importancia la estandarización o normalización y la división o particionamiento de los datos.

La normalización transforma las variables de entrada a un mismo rango de valores, a fin de evitar que la red neuronal sea influenciada por valores extremos; afectando su capacidad de aprendizaje y generando un modelo no apropiado. Para ello, se pueden aplicar funciones lineales, estadística o normalización simple; sin embargo, depende de la función de activación seleccionada (Zhang et al., 1998). Los rangos de normalización están condicionados por la función de transferencia aplicada, pero en general varían entre -1 a 1.

La división de los datos está destinada para la evaluación del modelo en las etapas de calibración y validación. En gran parte de la bibliografía sugieren dividir la información en base a porcentajes, por ejemplo, 70 – 30%, 80 – 20%, 90 – 10%, etc.; para calibración y validación, respectivamente. En el caso de las redes neuronales, el proceso de calibración, se conoce como entrenamiento. Wang et al. (2017) indican que se puede aplicar validación cruzada a fin de evitar problemas de sobreajuste de los datos. Para lo cual, los datos deben ser particionados en tres conjuntos: calibración, para calibrar los parámetros del modelo; validación, para detener la etapa de calibración; y, verificación, para probar la precisión de la simulación del modelo.

2.1.5 Evaluación del modelo

La red neuronal es evaluada mediante métodos gráficos y estadísticos, con ello, se puede cuantificar la precisión en las predicciones de caudales. El método gráfico está definido por hidrogramas, básicamente. En tanto que, existen diversas funciones estadísticas que pueden ser aplicadas; las métricas seleccionadas son (Moriasi et al., 2007):

Error cuadrático medio (MSE)

Coeficiente que mide el promedio de los errores al cuadrado, en las unidades de los datos analizados, y se determina por la ecuación:

$$MSE = \frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{n} \quad (2.6)$$

En dónde, \hat{Q}_i son los datos modelados, Q_i son los datos observados y n es el total de valores analizados. Además, cuando es cero significa un ajuste perfecto.

Coeficiente de Nash-Sutcliffe o coeficiente de eficiencia (NS)

Este coeficiente indica que tan bien se ajustan los valores observados con los simulados a una línea 1:1, y está dado por la expresión (Moriassi et al., 2007):

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (2.7)$$

En dónde, O_i es el valor observado, P_i es el valor simulado y, \bar{O} es la media de los valores observados, y n el número total de observaciones. El valor de NS oscila entre $-\infty$ y 1, por ende, debe maximizarse. El valor de 1 es su valor óptimo, valores entre 0 – 1 son generalmente considerados como aceptables de rendimiento y valores menores a 0 indican que el valor medio observado es mejor predictor que el valor simulado, es decir que el rendimiento del modelo es inaceptable. En la Tabla 2.2 se presenta una calificación del modelo en base del valor de NS obtenido.

Tabla 2.2 Rendimiento del modelo en función del NS

Calificación	Rango
--------------	-------

Muy bueno	$0.75 < NS \leq 1.00$
Bueno	$0.65 < NS \leq 0.75$
Satisfactorio	$0.50 < NS \leq 0.65$
Insatisfactorio	$NS \leq 0.50$

Elaboración: Xavier Maza, 2019. **Fuente:** (Moriassi et al., 2007).

Coeficiente de correlación de Pearson (R)

Representa el grado de colinearidad entre los datos observados y simulados y está dado por:

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O}) \times (P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \times \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \quad (2.8)$$

En dónde, P_i son los n flujos modelados, O_i son los n flujos observados, \bar{O} es la media de los flujos observados, y \bar{P} es la media de los flujos modelados. Este coeficiente varía entre -1 y 1. Si es cero significa que no existe relación lineal.

Porcentaje Bias (PBIAS)

Mide la tendencia promedio de los datos simulados en ser más grandes o pequeños con respecto a los datos observados, es decir, es la desviación de los datos expresado en porcentaje; y se define por:

$$PBIAS = \frac{\sum_{i=1}^n (O_i - P_i) \times 100}{\sum_{i=1}^n O_i} \quad (2.9)$$

En dónde, O_i es el valor observado, P_i es el valor simulado. El valor óptimo del PBIAS es cero, valores cercanos muestran la precisión del modelo; además, si es positivo indica subestimación, y si es negativo representan sobrestimación del modelo.

3. Capítulo III.

Materiales y Métodos

3.1 Área de Estudio

La zona de estudio se enfoca en el río Tomebamba y en la microcuenca del río Matadero; los cuales, se encuentran dentro de la cuenca hidrográfica del río Paute. La cuenca del río Paute se ubica en la zona centro sur de la sierra ecuatoriana, cubriendo un área de 5066 km² y formando parte de las provincias del Azuay, Cañar, Chimborazo y Morona Santiago. La microcuenca se localiza al norte de la provincia del Azuay, fue definida tomando como punto de cierre el sector conocido como Sayausí. Adicionalmente, se ha seleccionado un tramo de 6.76 km del río Tomebamba, el cual atraviesa la ciudad de Cuenca en dirección noroeste – sureste, ubicado aproximadamente 4km aguas abajo de la estación Matadero en Sayausí (UTM 714626 E, 9681640 N), entre los sectores de Balzay y antes de la junta con los ríos Yanuncay y Tarqui como se presenta en la Figura 3.1.



Figura 3.1. Tramo del río Tomebamba que será empleado para la modelación hidrodinámica

Elaboración: Xavier Maza, 2019.

La microcuenca del río Matadero se localiza en la zona oeste de la cuenca del río Paute, entre las coordenadas UTM-WGS84-17S 695000 – 715000 Este y 9675000 – 9700000 Norte. Abarca una superficie de 299.50 km² y presenta elevaciones que varían entre los 2678 a los 4428 msnm, ver Figura 3.2.




Figura 3.2. Microcuenca del río Matadero tomando como punto de cierre el sector de Sayausí

Elaboración: Xavier Maza, 2019.

3.1.1 Geología, Cobertura y Uso del suelo y de la microcuenca

A partir de cartografía base a escala 1:100000 se ha identificado que en la parte central de la microcuenca se presenta la formación Célica; la cual está formada por tobas andesíticas verdes muy meteorizadas y lavas andesíticas a andesito-basálticas. Al mismo la formación Tarqui se encuentra rodeando a la formación Célica; y está constituida por tobas y aglomerados (dacíticos, riolíticos y andesíticos) caolinizados, con bajo porcentaje de lava. Adicionalmente, se identifican zonas con presencia de lagunas glaciares y depósitos aluviales, coluvio-aluviales, de ladera, glaciares, fluvo-glaciares y superficiales (MAGAP, 2018).

A partir del mapa de coberturas y uso de suelo de la zona se determinaron las principales coberturas, en base al área de cada una con respecto al área total de la cuenca (299.50 km²); de modo que los suelos de páramo es la principal cobertura, abarcando aproximadamente el 80% de la microcuenca, los pastizales y bosques nativos ocupan un área alrededor del 9% y otros tipos de coberturas se presentan en áreas menores al 2%. En la Figura 3.3 se presentan las coberturas identificadas en la zona de estudio.




Figura 3.3. Cobertura y uso de suelo de la microcuenca de Matadero

Elaboración: Xavier Maza, 2019. **Fuente:** Cartografía a escala 1:100 000, MAGAP, 2014.

3.1.2 Características físicas de la microcuenca

En afán de establecer el comportamiento hidrológico de la microcuenca, se han determinado sus parámetros físicos. Basados en su área y coeficiente de forma, se puede clasificarla como una cuenca pequeña moderadamente achatada; además, de acuerdo a su coeficiente de compacidad, la cuenca es menos torrencial y de forma rectangular oblonga (Londoño, 2001). La zona de estudio tiene un área de drenaje baja (0.45 km^2) y con ello una respuesta hidrológica muy lenta; por lo tanto, se puede inferir que la cuenca posee suelos permeables y poco erosivos, lo cual coincide con el tipo de cobertura y uso de suelos presentados. En la Tabla 3.1 se presenta un resumen de los parámetros físicos, los cuales fueron calculados considerando un modelo digital de elevación (DEM) con tamaño de pixel de $3 \times 3 \text{ m}$.

Tabla 3.1 Parámetros físicos de la microcuenca

Descripción	Símbolo	Valor	Unidad
Área de la cuenca	A	299.50	km ²
Perímetro de la cuenca	P	108.50	km
Longitud del cauce principal	L	31.35	km
Longitud axial de la cuenca	L _b	23.63	km
Longitud total de los cauces	L _{tc}	133.95	km
Pendiente media de la cuenca	S	49.50	%
Elevación media de la cuenca	E	3712.03	msnm
Coeficiente de compacidad	K _c	1.76	-
Coeficiente de forma	K _f	0.54	-
Densidad de drenaje	D _d	0.45	km/km ²
Pendiente media	S ₁	5.45%	%
Pendiente media ponderada	S ₂	4.20%	%
Pendiente equivalente constante	S ₃	4.08%	%

Elaboración: Xavier Maza, 2019.

3.1.3 Hidrología de la microcuenca

De acuerdo a Mora et al. (2014), la microcuenca presenta un comportamiento hidrológico bimodal en función de la distribución de lluvia anual. Existe dos regímenes bimodales (BM1 y BM2). Casi la totalidad de la cuenca muestra un régimen BM1, excepto la parte baja (salida) de la cuenca que presenta un comportamiento BM2. El tipo BM1 se caracteriza por tener dos estaciones húmedas (marzo-mayo/septiembre-noviembre) y dos secas (junio-agosto/diciembre-febrero); y, con precipitaciones anuales de entre 700 y 900 mm. El tipo BM2 tiene un comportamiento similar a BM1, con precipitaciones anuales alrededor de 1000 mm.

El ciclo anual bimodal es determinado por el desplazamiento de la zona de convergencia intertropical y está influenciado por las corrientes de aire del Océano Pacífico y el anticiclón del sur. Las corrientes de aire se dan en dirección oeste-este y son modificadas por el fenómeno de El Niño; en



tanto que, el anticiclón del sur previene las precipitaciones en la parte sur de la cuenca del río Paute. Además, la distribución BM2 es afectada por el aumento de la humedad costera a lo largo de las laderas de los Andes occidentales (Mora et al., 2014).

3.1.4 Estaciones de monitoreo

Dentro de la microcuenca se han identificado la presencia de 12 estaciones de monitoreo, de las cuales siete pertenecen al PROMAS y las restantes están a cargo de ETAPA-EP. Las estaciones están repartidas principalmente en la zona central de la microcuenca; además, del total de estaciones, siete son pluviográficas (precipitación), cuatro son hidrográficas o limnigráficas (caudal) y existe una estación meteorológica (variables climáticas). En la Tabla 3.2 y en la Figura 3.4 se presenta la ubicación y nombre de las estaciones identificadas en la zona de estudio.

Tabla 3.2 Listado de estaciones de monitoreo presentes en la microcuenca

Institución	Nombre de la estación	*Código	Tipo	Este	Norte
PROMAS (P)	Llaviuco	P_LL	Hidrográfica	706457	9685644
	Marianza	P_MA	Meteorológica	708644	9684239
	Marianza Pajonal 1 (Bajo)	P_MAPA1	Pluviográfica	708611	9684320
	Marianza Pajonal 2 (Alto)	P_MAPA2	Pluviográfica	709221	9684392
	Marianza Pinos	P_MAPI	Pluviográfica	709876	9684662
	Mazan Pajonal	P_MAZPA	Hidrográfica	709346	9685090
	Mazan Pinos	P_MAZPI	Hidrográfica	710455	9684041
ETAPA-EP (E)	Chirimachay	E_CHI	Pluviográfica	705704	9688907
	Llaviucu	E_LL	Pluviográfica	705552	9685495
	Matadero en Sayausí	E_MS_P	Pluviográfica	714625	9681639
	Matadero en Sayausí	E_MS_Q	Limnigráfica	714626	9681640
	Sayausí PTAP	E_SPTAP	Pluviográfica	714701	9683793

*Los códigos fueron asignados en función del nombre de la estación y no corresponden a los códigos utilizados por cada institución

Elaboración: Xavier Maza, 2019.




Figura 3.4. Ubicación de las estaciones de monitoreo existentes en la microcuenca de Matadero

Elaboración: Xavier Maza, 2019.

3.2 Modelo de predicción de caudales

3.2.1 Información disponible

En la Figura 3.5 se presenta un esquema de la información hidrológica disponible hasta diciembre del 2017, para las estaciones de monitoreo existentes dentro de la zona de estudio. Como se puede apreciar, la estación denominada “Matadero en Sayausí” (E_{MS_Q} y E_{MS_P}) es la única estación de ETAPA-EP, que dispone de un amplio registro histórico de datos de precipitación y caudal, con un total de 20 años; además, la estación Chirimachay cuenta con un registro de ocho años. Mientras que, en el caso de PROMAS, existen cinco estaciones que presentan información completa de 12 años.

De manera que, para la construcción del modelo se han seleccionado las estaciones de Matadero en Sayausí y Chirimachay (ETAPA-EP), prescindiendo las estaciones del PROMAS; puesto que ésta institución no cuenta con un monitoreo continuo, de ahí que no existe información posterior a septiembre de 2017.




Figura 3.5. Porcentaje de información disponible por años de cada estación

Elaboración: Xavier Maza, 2019.

3.2.2 Implementación del modelo

La implementación del modelo de predicción de caudales con redes neuronales se construirá a través del software MATLAB® versión R2015a, y con ayuda de su paquete de herramientas denominado Neural Network Toolbox™, permiten crear diferentes arquitecturas de redes mediante una interfaz gráfica GUI y/o través de líneas de códigos que reemplazan dicha interfaz; en dónde se puede especificar cada uno de los parámetros que definen su arquitectura (algoritmo de aprendizaje, función de transferencia, tasa de aprendizaje, momentum, epochs y criterio de rendimiento).

Una vez identificado el funcionamiento de cada uno de los componentes que ofrece el Neural Network Toolbox para la construcción de la red neuronal y el modelo predictivo que mejor ajuste a los datos observados presenta; se ha optado por crear una codificación que reemplace la interfaz gráfica empleada. En vista que, para el desarrollo de la red neuronal únicamente se consideró el algoritmo de aprendizaje back-propagation tradicional con tasa de aprendizaje y momentum; por ende, se consideraron solo los parámetros de interés.

La codificación fue dividida en tres componentes: a) Datos: contiene funciones para importar la información con la que se va a trabajar (precipitación, caudal), normalización de los datos y creación de variables necesarias para la red neuronal; b) ANN: contiene la configuración de la red neuronal y cada uno de los parámetros que la definen; y, c) Evaluación: calcula las métricas para evaluar el rendimiento del modelo y permite graficar los datos observados y simulados, para la evaluación del modelo.



3.2.3 Escenarios de modelación

Los escenarios de modelación tienen por objeto establecer diferentes condiciones de la arquitectura de la red neuronal, a fin de establecer el modelo de predicción más adecuado para la microcuenca del río Matadero. En este sentido, los escenarios están relacionados con el establecimiento del número de neuronas para la capa de entrada y salida de la red.

El número de neuronas en la capa de entrada está definido por los valores de precipitación y caudal previos al tiempo de predicción t . Las neuronas en la capa oculta se obtendrán mediante ensayos de prueba y error variándolos de dos en dos hasta un total de 20; lo cual permitió establecer el mejor modelo y a la vez evitar problemas de sobreajustes. Mientras que, las neuronas en la capa de salida fueron definidas por los días de predicción de caudal que se desea realizar; los cuales serán a nivel diario desde 1 a 3 días. En vista de la información disponible se han planteado dos escenarios:

- Con la información de la estación Matadero en Sayausí.
- Con la información de las estaciones Matadero en Sayausí y Chirimachay.

Para construir los modelos para cada escenario propuesto se procedió de la siguiente manera:

1. Crear el vector con los datos de entrada (inputs) y salida (outputs).
 - a. Ingresar las series temporales de precipitación y caudal.
 - b. Normalizar los datos de precipitación y caudal.
 - c. Definir las neuronas para la capa entrada y corresponden al número de lluvias y caudales previos al caudal o caudales a predecir.
 - d. Definir el número de caudales a predecir, es decir, fijar la cantidad de neuronas para la capa de salida.
 - e. Crear una matriz de inputs y outputs.
2. Uso del Neural Network Toolbox
 - a. Importar las variables de entrada y salida
 - b. Crear la arquitectura de red neuronal (algoritmo de aprendizaje, criterio de rendimiento, número de capas, funciones de activación)
 - c. Modificar los parámetros de la red creada (tasa de aprendizaje, momentum, epochs)
 - d. Calibración del modelo, es decir el entrenamiento de la red neuronal creada.
 - e. Validación del modelo con un conjunto de datos diferente del empleado en la calibración.
3. Evaluar el rendimiento del modelo en cada etapa mediante las métricas definidas.
4. Evaluar el rendimiento del modelo gráficamente a través de una comparación de las series temporales observadas y simuladas.
5. Repetir el proceso a partir del paso 2.c. hasta obtener un modelo aceptable, considerando la evaluación cuantitativa y cualitativa.

3.3 Modelación hidrodinámica del río Tomebamba

3.3.1 Información disponible

La topografía constituye la información principal para la construcción del modelo fluvial del río Tomebamba y de manera complementaria ortofotos que permitan definir el tramo de estudio; a más de la hidrología del río para su evaluación. La topografía del tramo río Tomebamba desde el sector de Balzay hasta el sector Monay resultó de un DEM, el cual se obtuvo a partir de un levantamiento topográfico, LIDAR y complementado con información batimétrica del río con 242 secciones, espaciadas cada 25 m (ver Figura 3.1); esto permitió obtener un DEM de una resolución de 5 cm de tamaño de pixel. El archivo DEM fue elaborado por Jimenez y Ulloa (2019) para su trabajo de tesis de pregrado de ingeniería civil y el mismo fue empleado para el desarrollo de la presente investigación. Cabe mencionar que se llevó a cabo una revisión, en conjunto con los autores mencionados, de la información para validar la topografía del río Tomebamba.

3.3.2 Modelación hidrológica

Curvas IDF

Las curvas IDF representan gráficamente la relación entre intensidad de lluvia, duración y frecuencia o período de retorno de un evento de lluvia y nos permiten establecer la tormenta de diseño en el estudio hidrológico (Chow et al., 1994). Para la obtención de éstas relaciones se emplearon los registros históricos de las estaciones Chirimachay y Matadero en Sayausí, determinando las máximas alturas de lluvia para duraciones de 5, 10, 15, 20, 30, 60, 120, 360 y 1440 minutos. Los datos fueron ajustados a una distribución de probabilidad de Gumbel y posteriormente se realizaron pruebas de bondad de ajuste, siendo éstos el test de Kolmogorov-Smirnov y el coeficiente de determinación (R^2).

Tiempo de concentración y retardo

Se define como el tiempo requerido por una gota de agua en recorrer desde el punto más alejado de la cuenca hasta el punto de interés (Chow et al., 1994). Existen varias expresiones para estimar el tiempo de concentración de una cuenca hidrográfica, sin embargo, la ecuación adoptada es la de Kirpich y que es la más aceptada en estudios hidrológicos; y está dada por la siguiente expresión:

$$t_c = 0.0078 \cdot L^{0.77} \cdot S^{-0.385} \quad (3.1)$$

En dónde, t_c es el tiempo de concentración en minutos, L longitud del cauce principal en pies, S pendiente promedio en pies/pies; para este último parámetro, Maidment (1993) recomienda utilizar la pendiente del cauce entre el 10 y el 85% de su longitud total y está definida por:

$$S = \frac{\text{altura al 85\% de } L - \text{altura al 10\% de } L}{75\% \text{ de } L} \quad (3.2)$$

El tiempo de retardo es la diferencia de tiempo entre el centroide del hietograma de exceso de lluvia y el pico del hidrograma (Chow et al., 1994) y calcula como el 60% del tiempo de concentración, es decir:

$$t_r = 0.60 \times t_c \quad (3.3)$$

Método de Huff

Huff (1967) desarrollo relaciones de distribución de tiempo en tormentas intensas para áreas de hasta 1036 km² en términos de probabilidad, en el centro-este del estado de Illinois, Estados Unidos. De modo que, propuso una curva adimensional (curva de masa) entre la tormenta acumulada y su duración total y los clasificó en cuatro cuartiles (Tipo I, II, III y IV) de acuerdo a la duración de la tormenta; esta duración varía entre 3 a 6 hr, 6 a 12 hr, 12 a 24 hr y mayores a 24 hr para cada cuartil respectivamente.

Las curvas de Huff se determinaron con la información disponible de las series históricas de lluvia de las estaciones Chirimachay y Matadero en Sayausí en intervalos de tiempo de 20 minutos; para ello se ha empleado la metodología propuesta por Yin et al. (2016). En la Tabla 3.3 se presentan la cantidad de tormentas identificadas en cada cuartil para cada estación.

Tabla 3.3 Cantidad de tormentas clasificadas por cuartiles y estación

Estación	Tipo I	Tipo II	Tipo III	Tipo IV	Total
Chirimachay	21	50	48	49	168
Matadero en Sayausí	73	111	103	70	357

Elaboración: Xavier Maza, 2019.



Determinación de hidrogramas de crecida

Los hidrogramas de crecida para diferentes periodos de retorno fueron calculados con el método SCS dado por el Soil Conservation Service, para ello se ha empleado el programa HEC-HMS. El modelo requiere delimitar la cuenca de estudio y sus características, número de curva (CN), porcentaje de impermeabilidad, hietogramas de diseño y caudal base; para este último se debe fijar la constante de recesión y tasa de cambio al pico.

3.3.3 Implementación del modelo fluvial

La modelación hidrodinámica tiene como meta simular las condiciones hidráulicas naturales de los ríos mediante esquemas numéricos. Actualmente, existen diversos programas computacionales, libres y de pago, que permiten elaborar este tipo de modelos, entre los cuales se puede citar MIKE, HEC-RAS e Iber; y, los dos último fueron empleados para la investigación. Los dos son softwares libres que permiten la modelación matemática bidimensional de ríos; cabe mencionar que se trabajó en conjunto con el complemento HEC-GeoRAS para dibujar la geometría del río a partir del modelo digital de terreno.


3.3.4 Evaluación del modelo fluvial

La elaboración de un adecuado modelo fluvial del río implica un proceso de calibración del mismo, a fin de replicar lo más cercano posible, las condiciones naturales; es por ello que, para el proceso de calibración es necesario comprobar que los niveles de agua calculados (datos simulados) sean similares a los niveles naturales que se dan en el río (datos observados) según sean las condiciones en los que fueron medidos. La evaluación del modelo o proceso de calibración se realizó con HEC-RAS debido a la rapidez y facilidad del modelo, comparada con Iber; el cual constó de las siguientes etapas:

1. Asignar a todo el río un valor inicial de rugosidad de acuerdo a la literatura en base al tipo de material que se encuentra en el río Tomebamba.
2. Modificar el valor de rugosidad y comprobar visualmente el ajuste de los aforos con las curvas de descarga simuladas por el modelo.
3. Escoger el coeficiente de Manning que presente el mejor ajuste de caudales.

Curvas de descarga

Para llevar a cabo la evaluación del modelo se realizó una campaña de aforos en diferentes puntos del tramo de estudio (puentes) y además se contó con datos aforados previamente. Los aforos se realizaron con el método del molinete, que permite establecer el caudal que circula en el río mediante la medición de niveles de agua y velocidad en diferentes puntos a lo largo de la sección transversal. El equipo está compuesto por un molinete tipo Price, digitalizador, grúa de montaje y peso de sondeo. En la Figura 3.6 se presentan las curvas de descarga para cada sitio aforado.



Dónde: (a) Balzay, (b) Sagrados Corazones, (c) El Vado, (d) Todos Santos, (e) Hospital VCM. Los aforos en el puente de El Vado fueron proporcionados por PROMAS.

Figura 3.6. Curvas de descarga de las estaciones aforadas

Elaboración: Xavier Maza, 2019.

4. Capítulo IV.

Resultados y Discusión

4.1 Análisis hidrológico de las series temporales

Los esquemas que representa el comportamiento estadístico de los registros históricos de precipitación y caudal de las estaciones Matadero en Sayausí (MS) y Chirimachay (CH) se presentan en la Figura 4.1, Figura 4.2 y Figura 4.3; cabe mencionar que los diagramas fueron realizados con la información entregada por ETAPA a escala diaria, de modo que las series temporales estaban completas en todo el período analizado y no fue necesario hacer un relleno de datos por métodos convencionales. De acuerdo a los diagramas de caja para cada variable hidrológica, se ha identificado una gran cantidad de valores atípicos (outliers), los cuales disminuyen en función del intervalo de tiempo analizado; además, se puede ver que los meses de abril y mayo son las épocas más lluviosas y agosto y septiembre los meses menos lluviosos.




Figura 4.1 Serie temporal, diagrama de caja e histograma de precipitaciones de la estación MS a escala diaria, mensual y anual

Elaboración: Xavier Maza, 2019.




Figura 4.2 Serie temporal, diagrama de caja e histograma de caudales de la estación MS a escala diaria, mensual y anual

Elaboración: Xavier Maza, 2019.




Figura 4.3 Serie temporal, diagrama de caja e histograma de precipitaciones de la estación CH a escala diaria, mensual y anual

Elaboración: Xavier Maza, 2019.

La estación MS registra un valor medio de lluvia de 2.93 mm/día, mientras que para la estación CH es de 3.52 mm/día; también la estación MS registra un valor máximo de 68.50 mm/día y en CH es solo de 39 mm/día. En cuanto a los registros de caudal en MS, se puede ver que presenta un valor medio diario de 7.16 m³/s y un valor máximo diario de 103.20 m³/s, evento que ocurrió el 31/12/2017.

En el mapa de colores de la Figura 4.4, se presentan precipitaciones mensuales de MS para los 20 años de registros (1998 – 2017). En el esquema se puede notar que las épocas de mayor sequía se han dado entre los meses de julio y septiembre, con lluvias por debajo de los 25 mm/mes. Por otro lado, los meses más lluviosos han ocurrido entre febrero y mayo y entre octubre a diciembre, con registros sobre los 200 mm/mes. Al mismo tiempo, se puede identificar eventos extremos para cada año; como es el caso de marzo 2017 que se registra 260 mm, aproximadamente.




Figura 4.4 Heatmap de precipitación mensual para los registros históricos de la estación MS

Elaboración: Xavier Maza, 2019.

En el mapa de colores de la Figura 4.5, se presentan precipitaciones mensuales para los 8 años de registros (2010 – 2017) de la estación CH. En el esquema se puede apreciar que las épocas de mayor sequía se han dado entre los meses de septiembre y noviembre, con lluvias por debajo de los 25 mm/mes. Por otro lado, los meses más lluviosos han ocurrido entre febrero y abril, con registros alrededor de los 200 mm/mes. En este caso un evento extremo ocurrió en el 2015 con una lluvia máxima de 280 mm aproximadamente.





Figura 4.5 Heatmap de precipitación mensual para los registros históricos de la estación CH

Elaboración: Xavier Maza, 2019.

Adicionalmente, analizando los histogramas de medias mensuales (Figura 4.6), es evidente que las estaciones presentan un comportamiento hidrológico bimodal. La estación Matadero en Sayausí presenta dos picos de lluvia entre enero a mayo y octubre a diciembre sobre los 150 mm y 100 mm, respectivamente; los meses de julio y agosto presentan valores más bajos de precipitación, con lluvias por debajo de los 40 mm, aproximadamente. Al mismo tiempo, presenta una precipitación media anual de 1071.60 mm. La precipitación media anual de la estación Chirimachay es de 1285.90 mm y presenta similar comportamiento que la estación Matadero, no obstante, en el período seco la lluvia está por encima de los 50 mm; y en la época lluviosa se registran lluvias sobre los 90 mm.



Dónde: (a) Matadero en Sayausí, (b) Chirimachay

Figura 4.6 Precipitación media mensual de las estaciones MS y CH

Elaboración: Xavier Maza, 2019.



4.2 Modelo predictivo de caudales

4.2.1 Preparación de la información

Para la modelación en MATLAB se creó una base de datos en Excel con los registros de precipitación y caudal de las estaciones, valores que fueron truncados a uno y dos decimales, respectivamente; para efectos de ajustar las series temporales a un mismo formato. En este aspecto, se indica que caudales registrados el 11/11/2010 y el 05/01/2016 están en el orden de 0.004 m³/s, por lo cual en la base de datos corresponden a valores de cero; lo cual se ha considerado como despreciable en el modelamiento, tomando en cuenta la cantidad de datos ingresados al sistema. Por otro lado, en cuanto a datos de precipitación, dado que existen días en los que no llovió, se presentan varias secuencias de lluvia cero. Hung et al. (2009) indican que el principal problema con el uso de ANN en predicciones, es que usualmente solo se utilizan eventos o periodos de lluvia y por tanto el modelo no sería el adecuado para realizar pronósticos en tiempo real, puesto que no se toma en consideración el comportamiento completo de la cuenca. En este sentido, para la construcción del modelo, se han empleado todos los registros de las variables hidrológicas, incluyendo outliers (análisis estadístico) y valores de cero, ya que el objeto del modelo es dar predicciones en tiempo real.

La información fue preparada en hojas de Excel, en donde cada columna representa una variable hidrológica, luego estas fueron ingresadas a Matlab mediante códigos y, a la vez se convierte la información en pares de datos de entrada y salida; los cuales son función de la estructura del modelo y los escenarios analizados, es decir, que los datos de entrada y salida pueden ser más de un valor, por tanto, los pares de datos son matrices que definen el número de neuronas o nodos en la capa de entrada y de salida de la red neuronal, respectivamente. Además, los datos fueron normalizados a un rango de [-1, 1] porque se tuvo previsto trabajar con las funciones de activación sigmoidea y tangente. De igual manera, a fin de evitar problemas de sobreajustes, se aplicó validación cruzada, es decir que los datos fueron particionados para las etapas de entrenamiento, validación y prueba en la fase de calibración.

4.2.2 Análisis preliminar y selección de parámetros de la red

La capacidad de la red neuronal depende de la cantidad de neuronas en cada una de sus capas, a más de los parámetros que definen el algoritmo de aprendizaje back-propagation. Para determinar la cantidad de neuronas en la capa de entrada se ha llevado a cabo un análisis de autocorrelación de cada variable de cada estación, lo que permitió establecer la dependencia de precipitación y caudal con valores previos. Generalmente este análisis se emplea en modelos con enfoque lineal (ARIMA) pero fue la base para la selección preliminar de las variables de entrada.

Los diagramas ACF de la estación MS y CH se presentan en la Figura 4.7 y Figura 4.8, respectivamente. En el caso de la estación MS, la precipitación presenta una alta correlación hasta el lag 3, luego se vuelve constante; mientras que para el caso del caudal este comportamiento se presenta desde el lag 1, lo que no permite definir claramente cuál es el lag de mayor influencia; ante esto Coghlan (2016) establece que dicho comportamiento es probablemente debido al azar. De igual forma vemos que para la estación CH, existe una correlación alta hasta el lag 2, y después no se supera la banda de confianza.




Figura 4.7 Diagramas de autocorrelación de la estación MS

Elaboración: Xavier Maza, 2019.




Figura 4.8 Diagrama de autocorrelación de la estación CH

Elaboración: Xavier Maza, 2019.

Por lo tanto, para la predicción de caudal es recomendable emplear valores de tres días previos al día de predicción de lluvia de las estaciones MS y CH; y por lo menos un día previo de caudal de MS. A parte de la presencia de series continuas de lluvia cero, se ha considerado fundamental incluir valores previos de caudales en la capa de entrada, pues en caso de no hacerlo la red tendría que predecir caudales (altos y bajos) para secuencias de ceros; por lo que sería probable que el modelo tienda a ajustarse a un valor medio afectando el rendimiento del modelo.



A partir de los resultados estadísticos preliminares se estructuró un plan para la construcción de la arquitectura de red neuronal, de esta manera, se han planteado como objetivo crear modelos predictivos para 1 a 3 días; considerando como datos de entrada valores previos de precipitación y caudal previos al valor de predicción. Peng (2007) recomienda que para un análisis hidrológico la longitud de la información debe ser una secuencia de muestras mayor a 30 años, lo cual es altamente restrictivo para una modelación; en vista de que la estación MS dispone de 20 años de registros (1998-2017) y la estación CH tiene 8 años (2010-2017). Por lo que se plantearon dos escenarios, el primero consiste en construir el modelo considerando únicamente la estación MS, por tener 20 años de datos y el segundo considera las dos estaciones (MS y CH) incluyendo variables hidrológicas adicionales.

Para establecer los parámetros de la red que mejor se ajustan a las variables hidrológicas de la microcuenca del río Matadero, se llevó a cabo una modelación preliminar tomando en consideración únicamente los datos de la estación MS (Escenario 1 – E1), puesto que la estación dispone de 20 años de datos y dado que en este punto se van a realizar las predicciones de caudales, básicamente. Dicha modelación consiste en varios modelos a modo de prueba y error, a sabiendas que los siguientes parámetros pueden ser modificados:

- Número de neuronas en la capa de entrada, oculta y salida.
- Número de capas ocultas.
- Normalización de los datos.
- Funciones de activación.
- Tasa de aprendizaje
- Momentum

En base a las gráficas ACF de la estación MS, se optaron por cuatro nodos o neuronas en la capa de entrada, de los cuales uno es el caudal y tres son precipitaciones previas al caudal a predecir. La neurona en la capa de salida fue de uno, es decir, la predicción de un caudal diario. La herramienta NNTool de Matlab tienen por defecto valores para las neuronas en la capa oculta, la tasa de aprendizaje y el momentum; siendo éstos 10, 0.01 y 0.9 respectivamente. Además, la herramienta permite modificar el tipo de función de transferencia entre capas (entrada – oculta y oculta – salida), aunque por defecto define tangente y lineal para cada caso.

En una primera modelación se determinó el mejor rango de normalización para los datos, tomando por defecto la función de activación, las neuronas en la capa oculta, la tasa de aprendizaje y el momentum; y, se aplicaron tres rangos de normalización $[-1, 1]$, $[0, 1]$ y $[0.1, 0.9]$, siendo este último el rango que mejor modelo generaba. Con el rango definido se modificaron las funciones de transferencia por defecto (tangente y lineal), a pesar de ello, en todas las combinaciones posibles con las funciones sigmoidea y tangente se obtuvieron modelos con ajustes menores a los obtenidos por defecto. Tomando en cuenta que los valores de los pesos de las conexiones son valores aleatorios, estos resultados se consiguieron haciendo que éstos siempre sean los mismos valores aleatorios en cada modelación; al mismo tiempo, para evaluar los resultados solo se emplearon

métodos gráficos, al comparar la serie temporal de caudales observados y simulados. En la Figura 4.9 se presentan parte de los resultados del procedimiento expuesto, tomando todos los datos entre 1998 – 2017, con rango de normalización de $[-1, 1]$, tasa de aprendizaje de 0.01, momentum de 0.9 y 10 neuronas en la capa oculta y diferentes funciones de activación, en donde es evidente que los datos simulados no se aproximan a los observados.





Figura 4.9 Comparación de datos observados y modelados (primera aproximación)

Elaboración: Xavier Maza, 2019.

Posteriormente, y tomando los resultados de los dos parámetros antes analizados, se efectuó un análisis de sensibilidad de la tasa de aprendizaje y momentum para determinar los valores que mejor se ajustan, a través del coeficiente de Nash-Sutcliffe (NS), considerando que estos parámetros pueden variar entre (0, 1). En este caso la normalización de los datos se mantuvo en un rango de $[0.1, 0.9]$, con 10 neuronas en la capa oculta y las funciones de activación Tangente – Lineal, como se presenta en el esquema de la Figura 4.10.



Los números por debajo de cada recuadro indican el número de neuronas por capa. W: son los pesos las conexiones entre neuronas, b: es el bias, El grafico en rectángulo azul después del signo (+) es el tipo de función de activación empleado en la capa.

Figura 4.10 Arquitectura de red neuronal (NNTools)

Elaboración: Xavier Maza, 2019.

En la Figura 4.11 se presenta los resultados mediante un análisis de sensibilidad de Montecarlo para la tasa de aprendizaje y el momentum, las gráficas superiores son el resultado de 3040 modelaciones, mientras que las gráficas inferiores son el resultado de 289 modelaciones en las que se muestra el comportamiento de los dos parámetros; aquí la tasa de aprendizaje alcanza el mayor valor de Nash (NS) con valores alrededor de 0.85, en tanto que el momentum se encuentra alrededor de 0.35. De modo que se adoptaron dichos valores como los óptimos para la modelación. Una vez definidos éstos parámetros, mediante prueba y error se determinó el número de neuronas para la capa oculta, los resultados se indican en la Figura 4.12, y se puede ver que el coeficiente de eficiencia es prácticamente el mismo para el caso de 6 y 10 neuronas; sin embargo, se fijó este valor en 10 en caso de que se ingrese una mayor cantidad de datos, tomando en cuenta los escenarios propuestos. Adicionalmente, se analizó agregar otra capa oculta y se probaron diferentes neuronas en las dos capas, en algunos casos el aumento del coeficiente de Nash era mínimo, y en la mayor parte de casos empezaba a disminuir; por lo que no se consideró necesario trabajar con dos capas ocultas, ya que se incrementa el tiempo computacional y el modelo podría presentar sobreajustes de los datos.




Figura 4.11 Análisis de sensibilidad de la tasa de aprendizaje y momentum
Elaboración: Xavier Maza, 2019.




Figura 4.12 Análisis de sensibilidad de las neuronas en la capa oculta
Elaboración: Xavier Maza, 2019.

4.2.3 Escenarios de modelación

La predicción de caudales diarios de la microcuenca del río Matadero, se realizó mediante un análisis de comparación de dos escenarios, que difieren en la cantidad de parámetros de entrada para la red neuronal; hecho que está asociado a los registros históricos de las estaciones MS y CH y se trabajaron con los parámetros antes definidos y analizados. La base de datos fue dividida en dos partes para la etapa de calibración el 90% y para validación el 10% de los datos. Adicionalmente, la calibración fue dividida en tres subconjuntos (entrenamiento, validación y prueba) para evitar que la red tenga problemas de sobreajustes (validación cruzada), adoptando porcentajes de 60, 20 y 20% de los datos, respectivamente.

Escenario 1 – E1

El escenario 1 comprende la predicción de caudales considerando únicamente los registros históricos de la estación MS. En la Tabla 4.1 se presentan los mejores resultados alcanzados de los modelos planteados para E1, en donde A1, A2 y A3 corresponden a modelos de predicción para uno (Q_t), dos (Q_t, Q_{t+1}) y tres (Q_t, Q_{t+2}, Q_{t+3}) días respectivamente. Las entradas se refieren a la cantidad de variables hidrológicas que se ingresaron en la capa de entrada, indicando los valores de lluvia y caudales previos al día de predicción de la estación MS. Aquí se presentan los valores alcanzados para cada métrica durante las etapas de calibración y validación; el valor del MSE solo se considera en la calibración dado que este es el criterio (algoritmo back-propagation) para detener la fase de entrenamiento de la red neuronal.

Tabla 4.1 Resultados óptimos de los tres modelos del escenario 1

Modelo	Entradas		Calibración				Validación		
	P	Q	MSE	R	NS	PBIAS	R	NS	PBIAS
A1	3P	1Q	0.00077	0.8544	0.7299	-0.0251	0.7946	0.6244	5.0183
A2	3P	2Q	0.00113	0.7833	0.6132	0.0440	0.7242	0.5123	6.5744
A3	4P	2Q	0.00143	0.7263	0.5269	0.1101	0.6654	0.4165	9.9635

Dónde: P es la lluvia, Q es el caudal previo al día de predicción, y el número antes de P y Q indican los datos previos empleados (Ej. 3P = P_{t-3} , P_{t-2} , P_{t-1})

Elaboración: Xavier Maza, 2019.

A partir de los resultados indicados, podemos ver que los modelos A1 y A2 son buenos predictores de caudales basados en el coeficiente de NS, dado que su valor es superior a 0.50 para calibración y validación; en tanto que A3 no es adecuado en validación. Con respecto al coeficiente PBIAS, en la calibración los tres modelos presentan un entrenamiento adecuado, ya que se obtuvieron valores cercanos a cero y por tanto durante el entrenamiento de la red, no existirían sobre/subestimaciones significativas, sin embargo, durante la validación los tres modelos presentan subestimaciones. Y a la vez, el coeficiente R disminuye en la fase de validación con respecto a la calibración para los tres modelos.

A continuación, se presentan de manera gráfica la comparación entre los caudales observados y simulados por la red neuronal de cada modelo evaluado en E1. La Figura 4.13, Figura 4.14 y Figura 4.15 indican los resultados de calibración, sobre cada gráfica se presenta el valor de NS y PBIAS; en dónde se alcanza valores adecuados en entrenamiento y validación comparados con la fase de prueba. Al mismo tiempo, en los tres modelos, los caudales simulados exhiben el mismo comportamiento que los reales; a pesar de ello existe un mejor ajuste en caudales bajos que en caudales pico; además, en A2 y A3 las subestimaciones de caudales pico son mayores con respecto al modelo A1, en cada fase de la validación cruzada.




Figura 4.13 Etapa de calibración – A1
Elaboración: Xavier Maza, 2019.






Figura 4.14 Etapa de calibración – A2
Elaboración: Xavier Maza, 2019.


**Figura 4.15 Etapa de calibración – A3**

Elaboración: Xavier Maza, 2019.


La Figura 4.16, Figura 4.17 y Figura 4.18 presentan los resultados del proceso de validación para cada modelo, en dónde se puede ver que A1 muestra un comportamiento adecuado para caudales bajos, aunque se dan ciertas sobreestimaciones; mientras que en caudales picos, existen subestimaciones en todo el periodo analizado. Los modelos A2 y A3 presentan una tendencia similar a A1, pero las subestimaciones son más apreciables durante los meses de marzo – junio de 2016 y 2017. Igualmente, el coeficiente de eficiencia disminuye entre A1 y A3.

**Figura 4.16 Etapa de validación – A1**

Elaboración: Xavier Maza, 2019.

**Figura 4.17 Etapa de validación – A2**

Elaboración: Xavier Maza, 2019.

**Figura 4.18 Etapa de validación – A3**

Elaboración: Xavier Maza, 2019.

Escenario 2 – E2

El escenario 2 comprende la predicción de caudales considerando los registros históricos de la estación MS y CH, tomando en cuenta los datos entre 2010 – 2017, dado que las estaciones no tienen el mismo periodo de información (ver Figura 3.5); incluyendo dos variables hidrológicas adicionales. La primera se define como la lluvia ponderada diaria en función de las áreas de aporte de cada estación; se empleó este parámetro en vista que la estación MS se encuentra en la parte baja (salida) de la microcuenca, en tanto que la estación CH se ubica en la parte media. La ponderación se determinó en base a los polígonos de Thiessen de acuerdo al área de influencia de cada estación; dando como resultado que la estación CH cubre un área de 248.79 km² (83.07%) y la estación MS cubre un área de 50.71 km² (16.93%). El segundo parámetro adicional fue la lluvia acumulada diaria entre estaciones.

En la Tabla 4.2 se presentan los mejores resultados alcanzados de los modelos planteados para E1, en dónde B1, B2 y B3 corresponden a modelos de predicción para 1, 2 y 3 días respectivamente. La



arquitectura se refiere a la cantidad de neuronas en la capa de entrada y salida, indicando los valores de lluvia y caudales previos al día de predicción. En la tabla se presentan los valores alcanzados de cada métrica para las etapas de calibración y validación; del mismo modo, el valor del MSE solo se considera en la calibración dado que este es el criterio para detener la fase de entrenamiento de la red neuronal.

Tabla 4.2 Resultados óptimos de los tres modelos del escenario 2

Modelo	Entradas		Calibración				Validación		
	P	Q	MSE	R	NS	PBIAS	R	NS	PBIAS
B1	3PMS, 3PCH, 2PP, 2PAC	1Q	0.00212	0.8657	0.7488	-0.3408	0.8577	0.7073	8.3583
B2	3PMS, 2PCH, 5PP, 3PAC	4Q	0.00246	0.7921	0.6266	-0.5996	0.7712	0.5902	4.3407
B3	4PMS, 7PCH, 1PP, 3PAC	2Q	0.00314	0.7296	0.5294	-0.6949	0.7126	0.4874	7.7898

Dónde: P es la lluvia, Q es el caudal previo al día de predicción, PMS es la lluvia de la estación Matadero en Sayausí, PCH es la lluvia de la estación Chirimachay, PP es la lluvia ponderada, PAC es la lluvia acumulada y el número antes de P y Q indican los datos previos empleados (Ej. 3PMS = P_{t-3} , P_{t-2} , P_{t-1} de la estación MS)

Elaboración: Xavier Maza, 2019.

En las gráficas a continuación, se presenta la evaluación cualitativa entre caudales observados y simulados para cada modelo en E2. La Figura 4.19, Figura 4.20 y Figura 4.21 corresponden a los resultados de calibración, se puede apreciar que en entrenamiento y prueba tienen mejor ajuste (NS) en relación a la fase de validación; aunque para los diferentes modelos en las tres fases se presentan subestimaciones para caudales sobre los 40 m³/s aproximadamente. A la vez en la fase de prueba se puede apreciar que el modelo calcula caudales negativos para diciembre de 2016; aunque en general la tendencia de datos es similar. Y el coeficiente R disminuye en la fase de validación de cada modelo.




Figura 4.19 Etapa de calibración – B1
Elaboración: Xavier Maza, 2019.




Figura 4.20 Etapa de calibración – B2
Elaboración: Xavier Maza, 2019.




Figura 4.21 Etapa de calibración – B3
Elaboración: Xavier Maza, 2019.

La Figura 4.22, Figura 4.23 y Figura 4.24 presentan los resultados de validación de cada modelo, en dónde se puede ver que existe un buen ajuste en caudales bajos hasta alrededor de los 20 m³/s en los tres modelos; y, por tanto, existen subestimaciones para caudales superiores. Este problema principalmente se produce durante marzo – junio del 2017. En las gráficas se puede apreciar en los modelos B2 y B3 que los datos simulados van ligeramente desfasados con respecto a los observados, a diferencia de B1 en el que la mayor parte del periodo analizado los caudales se ajustan.






Figura 4.22 Etapa de validación – B1
Elaboración: Xavier Maza, 2019.

**Figura 4.23 Etapa de validación – B2**

Elaboración: Xavier Maza, 2019.

**Figura 4.24 Etapa de validación – B3**

Elaboración: Xavier Maza, 2019.

De acuerdo a los resultados obtenidos para E2 vemos que los valores de MSE y PBIAS resultan ligeramente superiores a E1, mientras que R y NS permanecen relativamente en el mismo rango para cada modelo, respectivamente. Al igual que en E1, los modelos de predicción de dos días (B1, B2) presentan resultados aceptables para calibración y validación, tomando en consideración el coeficiente NS; de modo que el modelo B3 no resulta apropiado. A la vez, en los tres modelos se producen sobreestimaciones en la fase de calibración y subestimaciones en la validación considerando los valores del PBIAS.

Así mismo, se observó que el uso de la precipitación ponderada y acumulada mejoró el rendimiento comparado con los modelos en los que se emplearon solo la lluvia de las dos estaciones. El uso de las dos variables adicionales tenía influencia, principalmente en la etapa de validación y en caudales bajos, a pesar de que en la evaluación cuantitativa (MSE, R, NS y PBIAS) no existían diferencias significativas.

Comparación de escenarios

Los seis modelos fueron planteados bajo las mismas configuraciones de parámetros que definen la arquitectura de la red neuronal, siendo éstas el rango de normalización, las funciones de activación, la cantidad de neuronas en la capa oculta, la tasa de aprendizaje, el momentum y un número



máximo de iteraciones (epochs) de 10,000. La diferencia en los escenarios radica en la cantidad de información empleada para cada escenario, en E1 se considera 20 años de registros de la estación Matadero en Sayausí (1998 – 2017), en tanto que E2 emplea 8 años de información (2010 – 2017) de las estaciones Matadero en Sayausí y Chirimachay, a más de las dos variables antes mencionadas.

La configuración de los modelos en E1 fue realizada a partir del análisis preliminar (sección 4.2.2) en la que se definieron ciertas variables (tasa y momentum) y los resultados se alcanzaron en base a la combinación de variables de entrada de lluvia y caudal; por consiguiente, E1 es el resultado de dicho análisis. Por otro lado, los modelos de E2 inicialmente se configuraron únicamente con datos de MS y CH; pero con dicha información se obtuvieron modelos con rendimiento menor a E1, sobre todo en la etapa de validación. Es por ello que fue necesario agregar parámetros de entrada, y en vista de la falta de información de las estaciones, se optó por calcular la precipitación ponderada y acumulada; de esta manera, las métricas empleadas para la evaluación cuantitativa de los modelos mejoraron. Considerando que en E2 se utilizan datos diferentes a E1, se analizó modificar las funciones de activación, tasa de aprendizaje y momentum, sin embargo, al cambiar el primer parámetro se obtenían resultados desfavorables; y, al modificar los dos últimos no se generaban mayores cambios, lo cual se determinó a partir de un análisis Monte Carlo; de modo que, se optaron por los valores establecidos en el análisis preliminar.

Por lo tanto, los dos escenarios planteados resultan ser adecuados para predicciones de caudales de hasta un día. De acuerdo al análisis cuantitativo, se puede ver que no existen diferencias marcadas entre los modelos A1 y B1; a pesar de ello, en el análisis cualitativo es indudable que A1 resulta más aceptable que B1, ya que es capaz de predecir caudales sobre los 20 m³/s y a la vez las subestimaciones en caudales pico no es tan marcada. De esta manera, vemos que la red neuronal E1 tiene una mejor capacidad de predicciones con respecto a E2, puesto que emplea una mayor cantidad de información y por ello la red neuronal es capaz de predecir los caudales a la salida de la microcuenca.

4.3 Modelo hidrodinámico

4.3.1 Modelación hidrológica

La modelación hidrológica tiene por objetivo establecer los hidrogramas de crecida para seis periodos de retorno considerados (2, 5, 10, 25, 50 y 100 años) a fin de analizar las posibles áreas de inundación en el río Tomebamba. En este sentido, mediante el software HEC-HMS se establecieron dichos hidrogramas empleando el método SCS (Soil Conservation Service Method). Tomando en cuenta que la modelación fluvial se realizará a partir del sector de Balzay, éste punto fue considerado como el cierre de la cuenca para establecer el análisis hidrológico, de modo que posee un área de 319.94 km² y un tiempo de concentración de 206.05 min.

El número de curva se determinó en función del grupo hidrológico, tipo de suelo y cobertura de la cuenca. La información cartográfica de la cobertura del suelo fue combinada de dos bases de datos, gran parte de la cuenca (65.28% del área total) se obtuvo del PROMAS a escala 1:25,000 del año 2016; y, el área restante (34.72%) es información del geoportal de la Universidad del Azuay – UDA a escala 1: 50,000 para la zona del parque nacional El Cajas del año 2001; dado que se encuentra restringido la información del geoportal del MAGAP del área del Cajas, mientras que la información de la UDA se encuentra más detallado y va en concordancia con la información del proporcionada por PROMAS. El mapa de coberturas identificadas en la cuenca de Balzay se presenta en la Figura 4.25.




Figura 4.25 Cobertura y uso del suelo de la cuenca con cierre en Balzay

Elaboración: Xavier Maza, 2019.

La cartografía del tipo de suelo de la cuenca se obtuvo del geoportal del MAGAP a escala 1: 250,000 del año 2003 y se identificaron cinco tipo de suelos como se indica en la Tabla 4.3. Los números de curva (CN) para cada una de las coberturas y según el grupo hidrológico al que pertenecen se presentan en la Tabla 4.4; los valores indicados en la tabla se obtuvieron en base a los valores recomendados por (Maidment, 1993; Estrella Delgado & Torres Lazo, 2017; Gutierrez et al., 2017).

Tabla 4.3 Tipo de suelo y grupo hidrológico existentes en la cuenca de Balzay

Tipo de suelo	Grupo Hidrológico
Entisol	A
Inceptisol	B
Alfisol	C
Vertisol	D
Mollisol	D

Elaboración: Xavier Maza, 2019.

Tabla 4.4 Números de curva para cada grupo hidrológico en función de las coberturas presentes en la cuenca de Balzay

Cobertura	A	B	C	D
Área Poblada	89	92	94	95
Bosque Nativo	36	60	73	79
Cuerpos de agua	100	100	100	100
Cultivos	67	76	82	86
Afloramientos rocosos	82	82	82	82
Paramo	43	65	76	82
Pastizal	68	79	86	89
Plantación Forestal	56	67	78	89
Suelo Descubierto	77	86	91	94
Vegetación Arbustiva	48	67	77	83
Vegetación Herbácea	48	67	77	83
Vías	98	98	98	98

Elaboración: Xavier Maza, 2019.

En función del área de cada cobertura se ha establecido que el número de curva es de 69.20. Además, se ha considerado que el tiempo de retardo (lag time) corresponde al 60% del tiempo de concentración ($123.63 \text{ min} \approx 2.06 \text{ hr}$), una constante de recesión de 0.90 y una tasa de cambio de 0.1 (ratio), éstos dos últimos parámetros son necesarios para el HEC-HMS. De igual manera, en

base a los registros históricos de caudales diarios en la estación Matadero en Sayausí se ha establecido el caudal base, definiéndolo como el caudal medio de invierno y cuyo valor es de 9.85 m³/s.

Un parámetro adicional corresponde a los hietogramas de diseño para los diferentes periodos de retorno seleccionados. Para lo cual se determinaron las ecuaciones Intensidad – Duración – Frecuencia (IDF) y las curvas de Huff de las estaciones Chirimachay y Matadero en Sayausí. Las ecuaciones IDF de cada estación se presentan en la Tabla 4.5 y las curvas Huff (Tipo I) para diferentes probabilidades se presentan en la Figura 4.26, cabe mencionar que para el estudio se utilizaron las curvas del 50% puesto que son las más representativas para la construcción de hietogramas de diseño (Bonta, 2004; Bezak et al., 2018) tomando un tiempo de diseño de 4 hr, ligeramente superior al tiempo de concentración (3.43 hr).

Tabla 4.5 Ecuaciones IDF para las estaciones CH y MS

Estación	5 < t < 30 min	30 < t < 120 min	120 < t < 1440 min
Chirimachay	$I = \frac{133.178 * Tr^{0.212}}{t^{0.340}}$	$I = \frac{384.611 * Tr^{0.213}}{t^{0.702}}$	$I = \frac{1335.618 * Tr^{0.200}}{t^{0.948}}$
Matadero en Sayausí	$I = \frac{208.489 * Tr^{0.217}}{t^{0.442}}$	$I = \frac{631.235 * Tr^{0.198}}{t^{0.787}}$	$I = \frac{1308.693 * Tr^{0.187}}{t^{0.919}}$

Dónde: I es la intensidad en mm/hr, Tr es el periodo de retorno en años, t es el tiempo en minutos

Elaboración: Xavier Maza, 2019.




Figura 4.26 Curvas de Huff para las estaciones CH y MS

Elaboración: Xavier Maza, 2019.

A fin de determinar los hietogramas de diseño de la cuenca de Balzay, se realizó una ponderación en función de los polígonos de Thiessen de acuerdo al área de influencia de cada estación. En la Figura 4.27 se presentan los hietogramas de diseño de la cuenca.




Figura 4.27 Hietogramas de diseño de la cuenca de Balzay

Elaboración: Xavier Maza, 2019.

En base a las variables antes indicadas se calcularon los hidrogramas de crecida para los seis periodos de retorno, los cuales se presentan en la Figura 4.28 y en la Tabla 4.6 se presentan los caudales pico de cada uno de ellos.




Figura 4.28 Hidrogramas de diseño para diferentes periodos de retorno

Elaboración: Xavier Maza, 2019.



Tabla 4.6 Caudales máximos obtenidos de los hidrogramas de diseño para diferentes períodos de retorno

Periodo de Retorno	Caudal
Años	m ³ /s
2	53.7
5	98.9
10	149.0
25	241.7
50	336.5
100	456.9

Elaboración: Xavier Maza, 2019.

4.3.2 Modelación hidráulica

Calibración del modelo con HEC-RAS

La geometría del río se obtuvo a partir de secciones transversales, cada 10 m, del modelo digital de elevación y secciones adicionales ubicadas en los puentes. La condición inicial fue un calado de cero. Las condiciones de contorno para el modelo se definieron como la pendiente de fricción aguas arriba y aguas abajo, para lo cual se recomienda el uso de la pendiente del fondo del lecho en el tramo cercano a la condición de contorno (US Army Corps of Engineers, 2016); las pendientes fueron tomadas del perfil longitudinal en los 550 m cercanos en cada caso, de modo que la pendiente aguas arriba resultó del 1.84% y aguas abajo del 0.56%. Por otra parte, la modelación del río se efectuó bajo condiciones de flujo permanente, es decir caudal constante; y, se modeló en flujo mixto (subcrítico y supercrítico). Dado que se disponían de aforos realizados en cinco puentes a lo largo del río, se eligieron seis caudales aforados para ser modelados tratando que cubran todo el rango de caudales que se tienen registrados; dichos caudales fueron 8.35, 11.67, 18.24, 24.68, 30.43 y 43.65 m³/s. Además, se consideraron dos coeficientes de rugosidad, uno para el cauce principal y otro para los márgenes del río. Bajo las condiciones antes mencionadas el proceso de calibración se enfocó en determinar los valores de Manning que mejor se ajustaban a las condiciones establecidas en el modelo.

A fin de definir el coeficiente de rugosidad, el área de estudio fue clasificada en tres zonas, siendo éstas el cauce, los márgenes del río y las zonas residenciales o urbanas; en la Figura 4.29 se presentan las zonas mencionadas. La asignación del coeficiente de Manning para cada zona se basó en inspecciones en campo y mediante comparaciones fotográficas del río con las sugeridas por Chow (1994). De esta manera, la rugosidad del cauce varía entre 0.03 – 0.05, para los márgenes

0.06 y para el caso de las zonas urbanas se asumió un valor de 0.15 según las recomendaciones del software Iber; este último fue utilizado en la modelación bidimensional.





Figura 4.29 Ortofoto del río Tomebamba y zonificación de suelos para el coeficiente de rugosidad
Elaboración: Xavier Maza, 2019.

Siguiendo la metodología presentada por Fernández de Córdova Webster et al. (2018) en la estimación del coeficiente de rugosidad del río Yanuncay, se calculó la rugosidad del lecho con el método de la medición de la velocidad con los registros de aforos de caudal realizados en los puentes ubicados en el sector del colegio Sagrados Corazones, Todos Santos y del paso universitario del Hospital VCM; como resultado el coeficiente de rugosidad variaba entre 0.02 y 0.047. En este contexto, se realizaron varias modelaciones modificando la rugosidad en el rango antes indicado para cada puente y comprobando los caudales simulados con los aforados; y, como resultado se tuvo que para valores entre 0.02 y 0.028 en algunos casos hubo un mejor ajuste en caudales bajos (alrededor del caudal base) pero se presentaban sobreestimaciones para caudales superiores. De igual manera, cuando la rugosidad fue modificada en el rango de 0.04 y 0.047 ocasionaron sub y sobreestimaciones de caudales.

Por lo tanto, se escogió un valor promedio de rugosidad y en ese punto fue ligeramente modificado hasta alcanzar el mejor ajuste visualmente entre las curvas de descarga generadas por HEC-RAS y los caudales aforados. En consecuencia, el coeficiente de Manning adoptado fue de 0.036. Los resultados de adoptar dicho valor como promedio para todo el tramo modelado del río Tomebamba se presentan en la Figura 4.30, en la cual se observa que existen sobreestimaciones de caudales altos ($>20 \text{ m}^3/\text{s}$) en los puentes de Balzay (a) y Corazones (b), sin embargo, tienen la misma tendencia con los datos aforados y se puede ver un mejor ajuste para el mismo rango de caudal en los puentes de Todos Santos (d) y Hospital VCM (e). A pesar de que para caudales bajos ($< 20 \text{ m}^3/\text{s}$) existen sub y sobreestimaciones, en el puente de El Vado (c) los caudales presentan la misma tendencia que los caudales simulados.



Dónde: (a) Balzay, (b) Sagrados Corazones, (c) El Vado, (d) Todos Santos, (e) Hospital VCM

Figura 4.30 Comparación de curvas de descarga simuladas con datos aforados

Elaboración: Xavier Maza, 2019.

Como resultado de las modelaciones en HEC-RAS se graficaron los perfiles de flujo las caudales simulados y con ello se pudo confirmar que en el río existe flujo mixto debido a las condiciones topográficas que presenta; en la Figura 4.31 se presentan el perfil de flujo y el calado crítico para el caudal de $43.65 \text{ m}^3/\text{s}$. Cabe mencionar que solo para los caudales de 8.35 y $11.67 \text{ m}^3/\text{s}$ no se presentaron desbordamientos en ninguna zona del río y para los caudales restantes existen desbordamientos al final del tramo, aproximadamente a unos 480 m antes de la junta con los ríos Yanuncay y Tarqui, lo cual se presenta en la Figura 4.32.




Figura 4.31 Perfil de terreno, de flujo y crítico para un caudal de 43.65 m³/s (tramo puente Balzay y Feria Libre)
Elaboración: Xavier Maza, 2019.




Figura 4.32 Nivel de agua para el caudal de 43.65 m³/s en el tramo final de modelación
Elaboración: Xavier Maza, 2019.



La geometría del río se obtuvo a partir del modelo digital de elevación con tamaño de pixel de 1x1 m y la geometría de los puentes (cotas). La condición inicial se definió con un calado de cero. La condición de contorno aguas arriba fue definida como flujo subcrítico con caudal total y corresponde a cada hidrograma de crecida (ver Figura 4.28), mientras que la condición aguas abajo se especificó como flujo subcrítico con salida tipo vertedero y altura cero, que representa a una salida con descarga libre, puesto que no se dispone de información adicional (ej.: curva de descarga); éstas consideraciones se hicieron en base a las recomendaciones dadas por Bladé et al. (2014). Adicionalmente, se realizó un mapa de cobertura de suelos (Figura 4.29) con los coeficientes de rugosidad previamente obtenidos en el proceso de calibración.

A continuación, desde la Figura 4.33 hasta la Figura 4.38 se presentan los mapas de calados máximos alcanzados en el tránsito de los hidrogramas, en éstos se puede apreciar las áreas de inundación que se generaron en cada caso. En el mapa de inundación para un periodo de retorno de 2 años, se han identificado desbordamientos del cauce principal a lo largo del tramo analizado, siendo la zona del Parque El Paraíso la mayor área afectada; puesto que existen inundaciones del área residencial en las dos márgenes del río, principalmente en la margen derecha. Por otro lado, en los mapas de inundación de los siguientes periodos de retorno, podemos ver que se incrementan los puntos de desborde y las áreas de afección con respecto al evento de crecida previo, como se aprecia en la Figura 4.39. En la Tabla 4.7 se presentan los calados y velocidades máximas alcanzadas en cada caso.

Tabla 4.7 Calados y velocidades máximas en la modelación de hidrogramas de crecida

Periodo de Retorno	Calado	Velocidad
años	m	m/s
Tr = 2	4.14	7.29
Tr = 5	4.84	7.90
Tr = 10	5.89	8.41
Tr = 25	8.20	9.04
Tr = 50	10.81	9.38
Tr = 100	11.54	10.36

Elaboración: Xavier Maza, 2019.




Figura 4.33 Mapa de calados máximos para un periodo de retorno de 2 años
Elaboración: Xavier Maza, 2019.




Figura 4.34 Mapa de calados máximos para un periodo de retorno de 5 años
Elaboración: Xavier Maza, 2019.




Figura 4.35 Mapa de calados máximos para un periodo de retorno de 10 años
Elaboración: Xavier Maza, 2019.




Figura 4.36 Mapa de calados máximos para un periodo de retorno de 25 años
Elaboración: Xavier Maza, 2019.




Figura 4.37 Mapa de calados máximos para un periodo de retorno de 50 años
Elaboración: Xavier Maza, 2019.




Figura 4.38 Mapa de calados máximos para un periodo de retorno de 100 años
Elaboración: Xavier Maza, 2019.




Figura 4.39 Máximas áreas de inundación para cada periodo de retorno (Tramo Puente Feria Libre – Puente Av. Unidad Nacional)

Elaboración: Xavier Maza, 2019.

Las velocidades máximas se presentaron en el eje del río aguas abajo del puente de la Av. Unidad Nacional y 100 m antes de la junta con los ríos Yanuncay y Tarqui, por lo que estos puntos constituyen zonas susceptibles a erosiones; en especial aguas abajo del puente por socavaciones en los estribos. En la Figura 4.40 se presenta la zona del puente para un periodo de retorno de 100 años, y se puede observar que para el resto del cauce las velocidades están alrededor de 5 m/s, es decir un 48% menor con respecto a la velocidad máxima y en las zonas de inundación son de 2 m/s (20% menor) aproximadamente. Para los demás periodos de retorno la relación entre velocidades en el cauce es similar y/o menor en las zonas de inundación.




Figura 4.40 Zona de velocidades máximas para un periodo de retorno de 100 años
Elaboración: Xavier Maza, 2019.

De igual manera se determinaron que para todos los periodos analizados se producen desbordamientos del cauce y causan inundaciones sobre la zona residencial, cubriendo áreas que van desde los 0.36 a 30.17 ha. En la Tabla 4.8 se indican el área que cubre cada caso, el porcentaje que representa con respecto al área residencial que fue considerada en el modelo (89.30 ha); y, el porcentaje adicional de área de inundación que representa con respecto al evento anterior.

Tabla 4.8 Áreas de inundación sobre la zona residencial

Periodo de Retorno	Área		
años	ha	% Total	% Adicional
Tr = 2	0.36	0.40%	-
Tr = 5	2.59	2.90%	2.49%
Tr = 10	6.34	7.10%	4.20%
Tr = 25	15.74	17.63%	10.53%
Tr = 50	23.40	26.20%	8.57%
Tr = 100	30.17	33.79%	7.59%

Elaboración: Xavier Maza, 2019.



Analizando los niveles de agua con los caudales simulados en HEC-RAS y en Iber podemos resaltar que el sector del parque El Paraíso es una zona continua de desbordamientos y por ello constituye un punto de interés en cuanto a peligrosidad. No obstante, en este punto confluyen los ríos Tarqui y Yanuncay y durante el periodo de invierno los caudales que transiten por dichos ríos tendrán una influencia directa en la zona, a la vez el cauce aumenta su sección transversal de modo que los niveles de agua podrían variar con respecto a los indicados en los mapas de inundaciones especialmente para periodos de retorno mayores a 10 años (ver Figura 4.35) que ya existen inundaciones en la zonas residenciales al final del tramo modelado.

Tomando en cuenta que a lo largo de las orillas del río existen parques lineales, senderos y ciclo vías en las dos márgenes, se determinaron los caudales en los cuales empiezan los desbordamientos del cauce, afectando dichas obras y en las zonas residenciales, a partir de la modelación en Iber durante la curva de crecida, descenso y agotamiento de los hidrogramas. En la Tabla 4.9 únicamente se presentan los caudales que producen desbordamientos y los sectores en los que ocurren. Para el caso de caudales que no se indique en la tabla significa que producirán aumento de los niveles de agua en los puntos que se encuentran previamente inundados.

Tabla 4.9 Zonas y caudales asociados a desbordamientos del río Tomebamba

Caudal m³/s	Sector Afectado	Margen del río	Caudal m³/s	Sector Afectado	Margen del río
15.70	Parque El Paraíso	D	113.40	Universidad	D
29.40	Parque El Paraíso	I		Hospital militar	I
49.00	Puertas del sol	I		Iglesia El Vergel	D / I
	Parque El Paraíso	D / I		Escuela de Enfermería de la UDC	D
	Edificio Terrassas	I		Aguas abajo puente Feria libre	I
51.70	Federación deportiva del Azuay	I		Aguas arriba puente Feria libre	I
53.70	Universidad de Cuenca	D	124.10	Ruinas de Pumapungo	D
	Hospital Militar	I	133.30	Aguas arriba puente Sagrados Corazones	D
56.50	Puertas del sol	D		Federación Deportiva del Azuay	D
82.80	Hospital militar	I		Aguas arriba puente Los Cedros	D
91.10	Vías de puertas de sol	I	140.40	Facultad de Ciencias Médicas	D
96.70	Radio Tropicana (Paraíso)	I	149.00	Aguas arriba puente Los Cedros	D / I



Tabla 4.9 Zonas y caudales asociados a desbordamientos del río Tomebamba (continuación)

Caudal m ³ /s	Sector Afectado	Margen del río	Caudal m ³ /s	Sector Afectado	Margen del río
166.70	Av. 12 de abril / Federación Deportiva del Azuay	D	224.00	Aguas arriba puente Roto	I
176.50	Puente de Balzay	D		Control urbano	D
	Atrás del Hotel Pinar del lago	I	241.70	Ministerio del trabajo	I
	Aguas abajo puente Balzay	D	292.50	Aguas abajo del puente Sagrados Corazones	I
	Aguas abajo puente Los Cedros	D		Aguas abajo del puente del Hospital VCM	D
185.90	Aguas arriba del paso peatonal del Hospital	D	430.70	Molinos del Batán	I
194.90	Aguas arriba del puente de la Av. Unidad Nacional	D		Plaza El Otorongo	D
	Ruinas de Pumapungo	I		Puente Universidad de Cuenca	D
	Hotel Europa	D		Puente Roto	I
210.90	Puente de Balzay	I		La casona del Puente Roto	D
	Hospital militar	D	446.10	Aguas arriba puente del Centenario	I
	Aguas abajo puente Roto	D	454.70	Plaza El Otorongo	I

Dónde: D es el margen derecho, I es el margen izquierdo

Elaboración: Xavier Maza, 2019.

A fin de establecer alertas por inundación, se fijaron umbrales basados en los caudales que producen desbordamientos del cauce y márgenes del río Tomebamba; es decir el caudal pronosticado en la estación Matadero en Sayausí debe ser comparado con dichos umbrales y a partir de ello se dará un nivel de alerta; en la Tabla 4.10 se indican los umbrales y las alertas definidas.

Tabla 4.10 Umbrales de alerta para inundaciones en el río Tomebamba

Caudal m ³ /s	Nivel de Alerta
≤ 15.50	Nula
$15.50 < Q < 24.00$	Baja
$24.00 < Q < 49.00$	Media
$Q \geq 49.00$	Alta

Elaboración: Xavier Maza, 2019.

Se ha establecido como alerta nula para caudales de hasta 15.50 m³/s puesto que con este caudal el agua permanece en el curso principal; como alerta baja para caudales menores a 24 m³/s puesto que hasta este valor no existe desbordamientos de los márgenes en todo el tramo analizado y para caudales superiores solo existe inundaciones en la parte central del parque El Paraíso (infraestructura); como alerta media hasta caudales de 49 m³/s dado que el cauce tiene capacidad para conducir dicho caudal sin provocar desbordamientos en las zonas residenciales; y, como alerta alta para caudales superiores a los 49 m³/s.

Cabe mencionar que a partir de caudales de 29.40 m³/s ocurrían desbordamientos a la zona residencial, en el sector del Parque El Paraíso; sin embargo, como se mencionó anteriormente, debido a la influencia de los ríos Yanuncay y Tarqui en el tramo final, los niveles no son confiables. Esto se justifica en el hecho de que se tiene un registro de aforo de caudal realizados el mismo día de 48.51 y 41.44 m³/s en los puentes de Balzay y del Hospital VCM respectivamente y estos no provocaron inundaciones en la zona residencial que se encuentra cercana al parque.

4.4 Integración del SAT

Una vez se encuentre en funcionamiento el SAT la institución a cargo de éste, en este caso ETAPA-EP, será el órgano regulador y encargado de difundir las alertas por inundación. Por otro lado, se considera fundamental realizar una cooperación conjunta con el ECU911 en vista que esta institución dispone de un sistema de cámaras de vigilancia en varios puntos de la ciudad, lo que permitirá monitorear el paso de un caudal por el río; y, a la vez es el organismo que reúne a Bomberos, Cruz Roja y Policía que son los requeridos para un control de las zonas vulnerables a inundaciones.





De acuerdo a Hill y Verjee citado por (Arteaga Naranjo, 2017), un SAT para inundaciones está compuesto por cuatro elementos siendo estos una red hidrometeorológica de monitoreo, infraestructura tecnológica, pronóstico de crecidas y difusión de alertas; de esta manera, ETAPA-EP



se encargaría de la red, la infraestructura y la difusión conjuntamente con el ECU911, en tanto que el modelo neuronal y fluvial del río Tomebamba componen las herramientas para el pronóstico de crecidas.

Los niveles de alerta fueron establecidos con el propósito de dar una señal de peligro frente a la ocurrencia de un caudal y para que provean información del evento y las acciones que deban seguir las instituciones a cargo del sistema. Mendoza et al. (2016) recomienda el uso de colores para los niveles de alerta; los cuales están asociados a ciertas condiciones que se deben tomar en cuenta en el monitoreo del modelo de predicciones y de acuerdo a ello, el coordinador general del SAT tomará la acción respectiva; como se indica en la Tabla 4.11.

Tabla 4.11 Niveles y acciones de alerta para el SAT

Nivel de alerta	Color de alerta	Condiciones en el monitoreo	Acción del coordinador
Nula		Cambios en las señales de peligro previas. (Ej.: cambios en los niveles de agua del río en la estación Matadero)	Revisión de información y seguimiento a la situación, en caso de ser necesario o incrementarse la situación cambiar a nivel amarillo o naranja.
Baja		Cambios en las señales de peligro previas. (Ej.: cambios en los niveles de agua del río en la estación Matadero)	Revisión de información, comunicación a la comunidad y seguimiento a la situación, en caso de ser necesario o incrementarse la situación cambiar a nivel naranja o rojo.
Media		Cambios en las señales de peligro previas, la emergencia podría estar muy cerca de ocurrir. (Ej.: incremento del nivel de agua en los márgenes del río)	Reunir el equipo integrante del SAT, probar el funcionamiento de todo, reforzar la información a la comunidad, tener todo listo para la emergencia, alistamiento preventivo 24 horas.
Alta		Cambios en las señales de peligro, la emergencia es inminente. (Ej.: incremento del nivel de agua cercano a la cota de desbordamiento en zonas residenciales)	Activar la alarma institucional de manera que en el tiempo establecido se realice la evacuación o protección acorde a la solución establecida por el SAT para salvar la vida de las personas.

Elaboración: Xavier Maza, 2019. **Fuente:** Adaptado de (Mendoza et al., 2016).



5. Capítulo V.

Conclusiones y Recomendaciones

5.1 Conclusiones

Las redes neuronales artificiales son modelos matemáticos que permiten representar el comportamiento hidrológico de una cuenca, con la ventaja de emplear una cantidad inferior de información, en cuanto a variables y a la extensión de éstas, a los modelos convencionales. Es así que se estableció un modelo capaz de predecir caudales a un día, con una adecuada precisión, tomando en cuenta los registros históricos de dos estaciones de la microcuenca del río Matadero.

La modelación con redes neuronales acarrió más de 3000 modelaciones, incluyendo el análisis de Montecarlo, análisis de sensibilidad de parámetros y los modelos con los mejores resultados de los dos escenarios propuestos (ver Tabla 4.1 y Tabla 4.2) y se encontró que los modelos más adecuados para predicciones de caudales son A1 y B1, los cuales presentan buenos resultados cuantitativos, pero de acuerdo a la evaluación cualitativa, A1 es el más óptimo para el caso de estudio. El modelo A1 es capaz de predecir caudales bajos y los picos hasta alrededor de los 50 m³/s; por lo que, en caso de que ocurran crecidas superiores a este, el modelo en su estado actual no tendrá la capacidad de hacerlo. De hecho, ahí recae el problema de modelos ANN, los cuales no son capaces de representar fenómenos que no hayan sido entrenados previamente; en consecuencia, el modelo continuamente debe ser entrenado con nueva información para que no se vuelva obsoleto y en efecto tenga la capacidad de realizar predicciones en tiempo real.

Por otra parte, se conoce que aguas arriba de la estación Matadero en Sayausí existen dos captaciones para el abastecimiento de agua a la ciudad de Cuenca; y, en caso de existir captaciones adicionales de las que no se tengan registros, disminuirían el caudal a la salida de la microcuenca. A pesar de ello, estas intervenciones no constituyen efectos desfavorables en modelos ANN, puesto que el modelo trabaja con caudales totales y por tanto no requiere información adicional, sobre todo relacionado con la hidrología sub-superficial, aunque está condicionado a la cantidad de información utilizada en la construcción del modelo. Prueba de ello es que el escenario E1 trabajó con 20 años de datos de lluvia y caudal, mientras que E2 se calibró con solo 8 años, pero fue necesario incrementar dos variables adicionales para complementar la falta de información. Por otra parte, incrementar la cantidad de variables de entrada no garantiza que el modelo sea capaz de trabajar apropiadamente y resulta necesario incrementar la cantidad de neuronas en la capa oculta, dando un modelo más robusto.

El incremento de los parámetros en la capa de entrada permite mejorar ligeramente la calibración, pero la validación no lo hace y en ocasiones disminuye su rendimiento de acuerdo a la evaluación cualitativa y cuantitativa; de modo que no se justifica incrementar la cantidad de neuronas de entrada si la variación del rendimiento del modelo es insignificante. Incluso, se estableció que al tener una cantidad de datos en la capa de entrada superior a 20 (Escenario 2), la red presentaba problemas de sobreajuste, a pesar de tener valores de NS aceptables en calibración, el problema era evidente en



la etapa de validación. Lo que llevo a descartar modelaciones con cantidades elevadas de neuronas de entrada y focalizarlas en un número menor en base a combinaciones de variables hidrológicas de las dos estaciones.

La división de datos para la validación cruzada en los porcentajes indicados obedece a las recomendaciones dadas de la revisión bibliográfica; a pesar de que se elaboraron modelos con porcentajes diferentes, se determinó que el rendimiento de los modelos disminuye con respecto a los presentados en el estudio. Este proceso garantiza que no existan problemas de sobreajuste, aunque varios modelos desarrollados presentaron este problema (análisis preliminar), pero esto ocurría debido a los valores elegidos inicialmente de la tasa de aprendizaje y momentum.

La selección del rango de normalización y función de activación o transferencia afecta el rendimiento del modelo. Al emplear un rango entre $[-1, 1]$ y la función tangente sigmoidea el modelo no es capaz de generalizar y aprender la problemática, por lo que trabaja mejor en rangos entre $[0, 1]$; mientras que para el mismo rango y con la función sigmoidea el modelo trabaja adecuadamente pero no produce modelos adecuados en función de las métricas empleadas. Por otra parte, al disminuir el rango de normalización a intervalos más pequeños a $[0.1, 0.9]$ en conjunto con la función tangente, el MSE mejora y se acerca más a cero, sin embargo, el modelo disminuye su rendimiento considerando los valores obtenidos de NS, R y PBIAS; por lo que el rango adoptado se considera adecuado, además, se justifica la necesidad de emplear más de una métrica para la evaluación de una red neuronal.

Los valores de los pesos fueron escogidos aleatoriamente en cada modelo y escenario analizado, sin embargo, para el análisis de sensibilidad los pesos siempre se fijaron en los mismos valores aleatorios a fin de establecer la variación de la tasa de aprendizaje y el valor del momentum. Al mismo tiempo, en el análisis preliminar se efectuaron varios modelos con valores aleatorios de los pesos, para ello se emplearon las funciones `rand` y `randn` de Matlab que permiten generar valores aleatorios con distribución uniforme y distribución normal, respectivamente; y, se les aplicaron diferentes factores para cambiar el rango de variación de los pesos. No obstante, la inicialización de los pesos con el uso de la herramienta NNTool de Matlab fue más adecuada puesto que los modelos convergían más rápido con respecto al uso de las funciones `rand` y `randn`.

Durante la etapa de entrenamiento o calibración de la red neuronal, los pesos se modificaban continuamente y por tanto los caudales simulados no eran los mismos entre modelos, por lo que antes de obtener los resultados definitivos en cada escenario, la red fue inicializada (pesos) tres veces para que exista un mayor ajuste en el modelo final. Este criterio fue adoptado ya que para las siguientes ocasiones que se inicializaban los pesos, los resultados de las métricas empleadas tenían muy poca variación.

La herramienta NNTool de Matlab permitió observar el comportamiento de la red durante la fase de calibración, en este sentido, los modelos en E1 generalmente convergían para el número máximo de iteraciones (10,000) sin embargo, para E2 en ocasiones los modelos lo hacían en un número inferior ($< 6,000$); lo que podría estar asociado a la cantidad de neuronas en la capa de entrada, es decir, se



ingresa mayor información y el modelo obtiene la respuesta deseada en menor iteraciones. Adicionalmente, se observó que disminuye la velocidad de procesamiento computacional en la etapa de calibración hasta alcanzar la convergencia del modelo, cuando se emplean pocos datos de entrada y/o si se consideran pocas neuronas en la capa oculta; en este último caso, el modelo converge rápido pero no es capaz de generalizar adecuadamente el problema y se tienen resultados como los presentados en la Figura 4.9. De manera que es importante seleccionar la cantidad de neuronas en la capa de entrada y oculta de la red neuronal.

En cuanto a la modelación fluvial es importante realizar una modelación bidimensional para representar los fenómenos que ocurren durante el tránsito de un determinado evento. El problema en el uso de Iber fue el tiempo computacional que requiere y la capacidad de hardware de la máquina. Esto restringió al uso de un modelo con tamaño de pixel de 1x1 m cuando se disponía de un DEM de 0.05x0.05 m y aunque se redujo el tamaño de la malla el programa tardaba entre 6 a 9 días en realizar una modelación. Por esta razón, se utilizó HEC-RAS para la calibración del modelo, reduciendo los tiempos computacionales.

La modelación de hidrogramas de crecida permitió analizar el comportamiento del tramo de estudio durante la curva de crecida, recesión y agotamiento y gracias a ello se identificaron los puntos de desbordamiento y zonas en las que se estancará el agua, una vez que el caudal empiece a disminuir, debido a su topografía; y, por lo tanto, necesitarán de drenajes adicionales que permitan la evacuación de las aguas ante la ocurrencia de los eventos analizados. Principalmente el paso a desnivel ubicado en la Av. 12 de Abril y José Peralta ya que, para eventos de crecida superiores a los 25 años, se inunda completamente y la capacidad de evacuación de sus drenajes podría no ser la adecuada; tomando en cuenta que para 100 años se tiene una carga de agua constante, es decir que la Av. 12 de Abril estaría inundada. Por consiguiente, en caso de crecida, se debería evacuar y cerrar los accesos a esta zona.

Los resultados alcanzados en el modelo de predicción y el modelo fluvial componen el Sistema de Alerta Temprana para la ciudad de Cuenca, dado que con el primero se pronostica el caudal con un día de anticipación en tanto que el segundo modelo demuestra el comportamiento fluvial del río frente a eventos de crecida; con lo cual se puede identificar las zonas de mayor impacto o riesgo de inundación, ante el caudal que fue pronosticado en la estación Matadero en Sayausí, aproximadamente 4 km aguas arriba del puente de Balzay, incluso con los umbrales ya establecidos se puede establecer un nivel de alerta sobre la ocurrencia de un determinado caudal. En consecuencia, se tiene una aproximación de la magnitud y alcance de inundación por la ocurrencia de un caudal que tendría sobre el río Tomebamba, lo cual es esencial para crear planes y estrategias de evacuación, pero esto debe ir acompañado de programas de educación sobre riesgos por inundaciones dirigidos a la población.

Por último, el objetivo de la investigación fue predecir caudales a nivel diario en base a los resultados alcanzados en un estudio previo, por lo que la información de caudales y lluvias solicitada a ETAPA-EP estuvo condicionada y recogida en esta escala y ya que el objetivo principal era establecer un modelo capaz de realizar predicciones en tiempo real, la literatura recomienda modelar la serie



histórica continua; en consecuencia, no se modelaron eventos de crecida específicos por separado. Del mismo modo, no se cuenta con registros de niveles de agua, en el tramo analizado del río Tomebamba, asociados con un caudal de crecida determinado por lo que los niveles de agua presentados en los mapas de inundación están basados en los aforos realizados para el presente estudio.

5.2 Recomendaciones y futuros trabajos

Con respecto al modelo de predicción de caudales se dan unas alternativas para aumentar su eficiencia. Tomando en cuenta que existen diversas arquitecturas de redes neuronales, se podría experimentar con otros tipos para aumentar el rendimiento del modelo; modificar la escala de predicción, es decir, realizar predicciones a nivel horario conservando la estructura aquí propuesta; o en su defecto una combinación de estas alternativas, lo que dependerá de la institución que se haga cargo y si existen nuevos objetivos para el modelo (escala de predicción).

En relación al modelo fluvial se recomienda modelar con más detalle la zona del parque El Paraíso debido a la confluencia con los ríos Tarqui y Yanuncay; en este caso se recomienda aplicar la metodología propuesta en cuanto al análisis hidrológico para tener las mismas condiciones de los eventos de crecida para distintos periodos de retorno que podrían ocurrir en las respectivas cuencas. Al mismo tiempo, se debería aumentar el levantamiento topográfico de la zona de confluencia para la respectiva modelación bidimensional.

Como posible trabajo futuro en el SAT sería la implementación conjunta del modelo de predicción de caudales con la transmisión de datos en tiempo real, de datos de lluvia y caudal de las estaciones de Chirimachay y Matadero; para que el modelo este en continuo funcionamiento. En este contexto, este complemento dependerá de ETAPA-EP ya que las estaciones mencionadas están a su cargo, tomando en cuenta que probablemente estaría condicionado a un convenio de participación entre la empresa y la Universidad de Cuenca. Adicionalmente, se deberá definir a detalle las acciones que debe realizar cada actor involucrado en el SAT, así como los protocolos de funcionamiento del sistema.



6. Referencias

- Abraham, A., 2005. Artificial Neural Networks, in: Handbook of Measuring System Design. John Wiley & Sons, Ltd.
- Aichouri, I., Hani, A., Bougherira, N., Djabri, L., Chaffai, H., Lallahem, S., 2015. River flow model using artificial neural networks. Energy Procedia 74, 1007–1014. <https://doi.org/10.1016/j.egypro.2015.07.832>
- Altunkaynak, A., 2007. Forecasting surface water level fluctuations of Lake Van by artificial neural networks. Water Resour. Manag. 21, 399–408.
- Araghinejad, S., 2013. Data-driven modeling: using MATLAB® in water resources and environmental engineering. Springer Science & Business Media.
- Arteaga Naranjo, M.O., 2017. Evaluación del modelo hidrológico HEC-HMS para la predicción hidrológica y de crecidas, en la cuenca baja del río Cañar.
- Beale, M.H., Hagan, M.T., Demuth, H.B., 1992. Neural Network Toolbox™ User's Guide, The Mathworks Inc.
- Bezak, N., Šraj, M., Rusjan, S., Mikoš, M., 2018. Impact of the Rainfall Duration and Temporal Rainfall Distribution Defined Using the Huff Curves on the Hydraulic Flood Modelling Results. Geosciences 8, 69. <https://doi.org/10.3390/geosciences8020069>
- Bladé, E., Cea, L., Corestein, G., Escolano, E., Puertas, J., Vázquez-Cendón, E., Dolz, J., Coll, A., 2014. Iber: herramienta de simulación numérica del flujo en ríos. Rev. Int. Métodos Numéricos para Cálculo y Diseño en Ing. 30, 1–10. <https://doi.org/10.1016/j.rimni.2012.07.004>
- Bonta, J. V., 2004. Development and utility of Huff curves for disaggregating precipitation amounts. Appl. Eng. Agric. 20, 641.
- Braham B, A., Varas C, E., 2003. Disminución de los tiempos de entrenamiento en redes neuronales artificiales aplicadas a hidrología. Ing. Hidráulica en México 18, 69–82.
- Campolo, M., Andreussi, P., Soldati, A., 1999. River flood forecasting with a neural network model. Water Resour. Res. 35, 1191–1197.
- Campolo, M., Soldati, A., Andreussi, P., 2003. Artificial neural network approach to flood forecasting in the River Arno. Hydrol. Sci. J. 48, 381–398. <https://doi.org/10.1623/hysj.48.3.381.45286>
- Chow, V. Te, 1994. Hidráulica de los Canales Abiertos. McGraw-Hill.
- Chow, V. Te, Maidment, D., Mays, L., 1994. Hidrología Aplicada. McGraw-Hill.
- Coghlan, A., 2016. A Little Book of R for Time Series. Parasite Genomics Group.
- Coulibaly, P., Anctil, F., Bobee, B., 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. J. Hydrol. 230, 244–257.
- Cuenca, C.C., 2002. Reforma, actualización, complementación y codificación de la ordenanza que sanciona el Plan de Ordenamiento Territorial del cantón Cuenca: Determinaciones para el uso y



- Dawson, C., Wilby, R., 2001. Hydrological modelling using artificial neural networks. *Prog. Phys. Geogr.* 25, 80–108.
- Estrella Delgado, D.C., Torres Lazo, J.V., 2017. Análisis hidrológico y diseño de la red hidrometeorológica en Cuenca de páramo: caso de estudio de Molleturo y Chaucha.
- Fernández de Córdova Webster, C.J., León Méndez, A.J.F., Rodríguez López, Y., Martínez Ramírez, P.G., Meneses Meneses, D.M., 2018. Influencia del método de estimación en el coeficiente de Manning para cauces naturales. *Ing. Hidráulica y Ambient.* 39, 17–31.
- Gutierrez, D.C., Méndez, D.P., del Salto, R.A.A., 2017. Determinación del parámetro hidrológico número de curva en la cuenca de la quebrada El Batán, usando sistemas de información geográfica y percepción remota. *FIGEMPA Investig. y Desarro.* 1, 31–41.
- Huff, F.A., 1967. Time distribution of rainfall in heavy storms. *Water Resour. Res.* 3, 1007–1019.
- Hung, N.Q., Babel, M.S., Weesakul, S., Tripathi, N.K., 2009. An artificial neural network model for rainfall forecasting in Bangkok, Thailand. *Hydrol. Earth Syst. Sci.* 13, 1413–1425.
- Jimbo Pinos, K.S., Reinoso Vázquez, F.A., 2008. Redes neuronales artificiales aplicadas en la predicción de caudales en la cuenca del Río Paute, Segunda fase. Universidad de Cuenca.
- Jimenez, J., Ulloa, L., 2019. Análisis de la capacidad de descarga y caracterización hidráulica en los puentes sobre el río Tomebamba en el tramo comprendido entre Balzain y Monay. Universidad de Cuenca.
- Kiş, Ö., 2004. River flow modeling using artificial neural networks. *J. Hydrol. Eng.* 9, 60–63.
- Li, H.-Y., Tian, L., Wu, Y., Xie, M., 2013. Improvement of mid-to long-term runoff forecasting based on physical causes: application in Nenjiang basin, China. *Hydrol. Sci. J.* 58, 1414–1422.
- Londoño, C., 2001. Cuencas hidrográficas: Bases Conceptuales, Caracterización, Planificación, Administración. Univ. del Tolima 1–350.
- MAGAP, 2018. Geoportal del Agro Ecuatoriano [WWW Document]. URL <http://geoportal.agricultura.gob.ec/>
- Maidment, D.R., 1993. Handbook of hydrology. McGraw-Hill New York.
- Maier, H.R., Dandy, G.C., 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environ. Model. Softw.* 15, 101–124.
- Mendoza, A., González, H., Buelvas, J., Martínez, S., 2016. Unidad Nacional para la Gestión del Riesgo de Desastres / Guía para la implementación de sistemas de alerta temprana comunitarios, 2da ed. Bogotá, Colombia.
- Minns, A.W., Hall, M.J., 1996. Artificial neural networks as rainfall-runoff models. *Hydrol. Sci. J.* 41, 399–417. <https://doi.org/10.1080/02626669609491511>



- Mora, D., Campozano, L., Cisneros, F., Wyseure, G., Willems, P., 2014. Climate changes of hydrometeorological and hydrological extremes in the Paute basin, Ecuadorean Andes.
- Moriasi, D.N., Arnold, J.G., Van Liew, M.W., Binger, R.L., Harmel, R.D., Veith, T.L., 2007. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Trans. ASABE* 50, 885–900. <https://doi.org/10.13031/2013.23153>
- Peng, Y., 2007. Method of long-term hydrological forecasting and optimal operation of reservoirs and its integration.
- Toth, E., Brath, A., Montanari, A., 2000. Comparison of short-term rainfall prediction models for real-time flood forecasting. *J. Hydrol.* 239, 132–147.
- US Army Corps of Engineers, 2016. HEC-RAS River Analysis System, User's Manual Version 5.0. US Army Corps Eng. Hydrol. Eng. Center, Davis CA 1–960. <https://doi.org/CPD-68>
- Vallejo Llerena, E.C., 2014. Análisis de las crecidas presentadas en los ríos Tarqui, Yanuncay y Tomebamba desde 1997 hasta 2011.
- Varoonchotikul, P., 2003. Flood Forecasting using Artificial Neural Networks, UNESCO-IHE. Swets & Zeitlinger.
- Veintimilla, J., Cisneros, F., Vanegas, P., 2016. Artificial Neural Networks Applied to Flow Prediction: A Use Case for the Tomebamba River. *Procedia Eng.* 162, 153–161. <https://doi.org/10.1016/j.proeng.2016.11.031>
- Wang, J., Shi, P., Jiang, P., Hu, J., Qu, S., Chen, X., Chen, Y., Dai, Y., Xiao, Z., 2017. Application of BP Neural Network Algorithm in Traditional Hydrological Model for Flood Forecasting. *Water* 9, 48.
- World Meteorological Organization, 2011. Manual on flood forecasting and warning.
- Yaseen, Z.M., El-Shafie, A., Afan, H.A., Hameed, M., Mohtar, W.H.M.W., Hussain, A., 2016. RBFNN versus FFNN for daily river flow forecasting at Johor River, Malaysia. *Neural Comput. Appl.* 27, 1533–1542.
- Yilmaz, A.G., Imteaz, M.A., Jenkins, G., 2011. Catchment flow estimation using Artificial Neural Networks in the mountainous Euphrates Basin. *J. Hydrol.* 410, 134–140.
- Yin, S., Xie, Y., Nearing, M.A., Guo, W., Zhu, Z., 2016. Intra-storm temporal patterns of rainfall in China using Huff curves. *Trans. ASABE* 59, 1619–1632.
- Zealand, C.M., Burn, D.H., Simonovic, S.P., 1999. Short term streamflow forecasting using artificial neural networks. *J. Hydrol.* 214, 32–48.
- Zhang, G., Patuwo, B.E., Hu, M.Y., 1998. Forecasting with artificial neural networks:: The state of the art. *Int. J. Forecast.* 14, 35–62.